

Autonome Fahrzeugführung in urbaner Umgebung durch Kombination objekt- und kartenbasierter Umfeldmodelle

Von der Fakultät für Elektrotechnik, Informationstechnik, Physik
der Technischen Universität Carolo-Wilhelmina zu Braunschweig

zur Erlangung der Würde

eines Doktor-Ingenieurs (Dr.-Ing.)

genehmigte Dissertation

von

Dipl.-Ing. Jan Effertz

aus Erkerode

Eingereicht am:	23. Februar 2009
Mündliche Prüfung am:	10. Juli 2009
Berichterstatter:	Prof. Dr.-Ing. W. Schumacher
Mitberichterstatter:	Prof. Dr.-Ing. J.-U. Varchmin

2009

Meinem Sohn Constantin

Vorwort

Das Thema der vorliegenden Arbeit ist während meiner Zeit als wissenschaftlicher Mitarbeiter am Institut für Regelungstechnik der Technischen Universität Braunschweig bearbeitet und im Zeitraum von April 2008 bis Dezember 2008 von mir neben meiner Tätigkeit bei der Volkswagen AG zu einer wissenschaftlichen Abhandlung zusammengefasst worden.

Mein Dank gilt allen Mitgliedern des Team CarOLO, insbesondere meinen Kollegen Jörn-Marten Wille, Kai Homeier, Christian Berger, Sebastian Ohl und Felix Klose für den gezeigten Teamgeist und die überdurchschnittliche Leistungsbereitschaft im Vorfeld und Verlauf des Urban Challenge Wettbewerbs. Mein besonderer Dank gilt in diesem Zusammenhang Herrn Prof. Dr.-Ing. Thomas Form, dessen Engagement und unermüdlicher Einsatz für das Projekt maßgeblich zum Erfolg beigetragen haben.

Darüber hinaus gilt mein Dank Herrn Prof. Dr.-Ing. Walter Schumacher, der mir die Möglichkeit zu dieser Arbeit gab, mir eigenständiges Arbeiten ermöglichte und das Thema stets durch innovative Ideen förderte.

Ich möchte weiterhin Herrn Prof. a.d. Dr.-Ing. Jörn-Uwe Varchmin für die Übernahme der Mitberichterstattung danken, den ich bereits vor Jahren als Mensch und Professor kennen und schätzen lernen konnte.

Ein besonderer Dank gilt meinen Eltern. Diese haben mich stets unterstützt und somit meinen Ausbildungsweg ermöglicht. Meinem Vater Günter Effertz und Herrn Gerrit Feige möchte ich für das geduldige Korrekturlesen dieser Arbeit danken.

Schließlich möchte ich die Gelegenheit Nutzen, meiner Frau Nina für ihre Liebe und Zuneigung zu danken. Sie hat während aller Höhen und Tiefen der letzten Jahre stets zu mir gehalten und musste nicht zuletzt während des Urban Challenge Wettbewerbs und in der Phase der Zusammenschrift mehr als einmal auf ihren Ehemann verzichten, der an dieser Stelle Besserung geloben möchte.

Erkerode, im Januar 2009

Jan Effertz

Inhaltsverzeichnis

Vorwort	V
Symbolverzeichnis	XIII
1 Übersicht	XVI
2 Einleitung und Motivation	1
3 Anforderungen und Stand der Technik	4
3.1 Anforderungen der Urban Challenge	4
3.2 Stand der Technik	7
3.2.1 Sensorik zur Umfeldwahrnehmung	7
3.2.2 Umfeldmodellierung und Datenfusion	9
3.2.3 Bahnplanung	11
3.3 Übertragung auf den urbanen Bereich und Weiterentwicklungsbedarf	13
4 Architektur für die autonome Fahrzeugführung	15
4.1 Versuchsträger und Hardwarekomponenten	17
4.1.1 Umfelderkassende Sensorik	17
4.1.2 Ortungssystem	20
4.1.3 Rechnersystem und Fahrzeugintegration	21
4.2 Wahrnehmungsebene und hybrides Umfeldmodell	22
4.3 Interpretations- und Aktionsebene / Bahnplanung	24
4.3.1 Grundlegende Fahrzeugführung nach DAMN	25
4.3.2 Zustandsbasierte Erweiterung der Fahrzeugführung	28
4.3.3 Dynamische Bahnoptimierung	30
4.4 Ausführungsebene	31
4.4.1 Längs- und Querregelung	31
4.5 Überwachungsebene	33
5 Theoretische Grundlagen	35
5.1 Der Bayes'sche Filteralgorithmus	36
5.2 Objektbasierte Umfeldmodellierung	39
5.2.1 Prozessmodell im Zustandsraum	39
5.2.2 Kalman Filter	42
5.2.3 Erweitertes Kalmanfilter	45
5.2.4 Sigma-Punkt Filtervarianten	46
5.2.5 Weiterführende Schätzverfahren und Auswahlkriterien	49

5.2.6	Objekttracking	53
5.3	Kartenbasierte Umfeldmodellierung	57
5.3.1	Bayes'sche Belegungskarten	57
5.3.2	Binärer Bayes Filter mit statischem Zustandsvektor	59
5.3.3	Einschränkungen der Bayes'schen Betrachtungsweise	62
5.3.4	Dempster-Shafer Theorie	63
5.3.5	Belegungskarten auf Basis der Evidenztheorie	66
5.3.6	Vergleich der Bayes- und Dempster-Shafer-Methodik	67
5.4	Sensorfusion	68
5.4.1	Objektbasierte Sensorfusion	68
5.4.2	Kartenbasierte Sensorfusion	70
6	Objekttracking in urbaner Umgebung	72
6.1	Objektmodell auf Basis lokaler Karten	72
6.1.1	Dynamikmodell	74
6.1.2	Systemrauschen	77
6.1.3	Eingangsdaten und Messrauschen	78
6.2	Aufbau der Tracking-Algorithmen	81
6.3	Datenassoziation	82
6.3.1	Stufe-1-Assoziation	83
6.3.2	Stufe-2-Assoziation	86
6.3.3	Optimierungsalgorithmus	86
6.4	Zustandsschätzung für das Freiform-Modell	88
6.4.1	Mehrdeutigkeit von Rotation und Translation	89
6.4.2	Vereinfachte Filtergleichung	90
6.4.3	Diskussion der Näherung	94
6.5	Adaptives Pretracking zur Objektinitialisierung	98
6.5.1	Optimierung durch Kopplung mit Befahrbarkeitsanalyse	101
7	Kartenbasiertes Umfeldmodell zur Fahrbereichsanalyse	102
7.1	Datenfluss und prinzipieller Ablauf	103
7.2	Datenstruktur und Verwaltung der Karte	106
7.2.1	Rechnerarchitektur und Speicherlayout	107
7.2.2	Optimierte Datenstruktur für die Echtzeit-Anwendung	109
7.3	Höhenbasierte Befahrbarkeitsabschätzung	110
7.3.1	Aktualisierung des Höhenprofils	111
7.3.2	Raycasting-Algorithmus	112
7.3.3	Interpolation und Gradientenanalyse	117
7.3.4	Probabilistische Interpretation der Gradientendarstellung	122
7.4	Farbbasierte Befahrbarkeitsabschätzung	124
7.4.1	Klassifikation im Bildbereich	124
7.4.2	Transformation in das kartenbasierte Umfeldmodell	127
7.4.3	Probabilistische Interpretation der farbbasierten Klassifikation	129
7.5	Zeitliche Integration und Datenfusion	130
7.6	Anpassung an dynamische Vorgänge	131

8	Evaluation und praktische Ergebnisse	133
8.1	Objekt-Tracking	134
8.1.1	Szenario 1: Geradlinige Fahrt mit konstanter Geschwindigkeit	135
8.1.2	Szenario 2: Geradlinige Fahrt mit konstanter Beschleunigung	137
8.1.3	Szenario 3: Fahrt in Schlangenlinien	139
8.2	Fahrbereichsanalyse	141
8.2.1	Szenario 1: Begrenzung durch Bordstein / Grünstreifen	141
8.2.2	Szenario 2: Begrenzung durch Randbebauung / Böschung	144
8.2.3	Szenario 3: Rampe	146
8.3	Wettbewerbsverlauf	149
8.3.1	Halbfinale	149
8.3.2	Qualifikationslauf A: Interaktion mit Fließverkehr	149
8.3.3	Qualifikationslauf B: Grundlegende Navigation, Parken und Freifahrt- zonen	152
8.3.4	Qualifikationslauf C	155
8.3.5	Finale	156
8.4	Fazit	162
9	Zusammenfassung und Ausblick	164
A	Koordinatensysteme und Transformationen	168
A.1	Allgemeine Koordinatentransformation	168
A.2	Festlegung der Koordinatendarstellungen	169
A.2.1	Kalibrierparameter der Sensorik	170
A.2.2	Umrechnung von geodätischen Koordinaten in Weltkoordinaten . . .	171
A.2.3	Umrechnung von Fahrzeug- in Weltkoordinaten	171
A.2.4	Transformation von Geschwindigkeiten	173
A.3	Besondere Koordinatensysteme	173
A.3.1	Diskrete Weltkoordinaten	174
A.3.2	Kamerakoordinaten	174
B	Fahrzeugarchitektur	177
	Literatur	179

Abbildungsverzeichnis

2.1	Team CarOLO, Finale DARPA Urban Challenge, November 2007	3
3.1	Grundlegende Fahranforderungen	5
3.2	Weiterführende Fahranforderungen	5
3.3	Übersicht Bahnplanungskonzepte	12
4.1	Architekturkonzept für die autonome Fahrzeugführung	16
4.2	Versuchsträger Caroline für die Urban Challenge 2007	17
4.3	Übersicht LIDAR-Scanner	18
4.4	Übersicht Mehrstrahl-LIDAR	18
4.5	Übersicht Radarsensorik	19
4.6	Kamerasystem zur Farbanalyse	19
4.7	Laserscanner zur Erfassung der Fahrbahnoberfläche	20
4.8	Ortungssystem und GPS-Empfangsantenne	21
4.9	Rechnersystem im Kofferraum des Versuchsträgers	22
4.10	Urbanes Umfeld im Urban Challenge Wettbewerb	23
4.11	Architektur der Fahrzeug-Umfelderfassung	24
4.12	DAMN-Konzept zur Fahrzeugführung	25
4.13	Kartenmaterial und Wegpunkt-Folgeverhalten	26
4.14	Hindernisdarstellung und Ausweichverhalten	27
4.15	Befahrbarkeitsdarstellung und Folgeverhalten	27
4.16	Kombination verhaltens- und ereignisgesteuerte Fahrzeugführung	28
4.17	Kreuzungsverhalten durch Ereignissteuerung	29
4.18	Spline-Interpolation zur dynamischen Bahnoptimierung	30
4.19	Struktur der Fahrzeug-Längsregelung	31
4.20	Struktur der Fzg.-Querregelung	32
4.21	Konzept zur Fahrzeugüberwachung	33
5.1	Rekursiver Filterprozess für die Umfeldwahrnehmung	35
5.2	Wahrscheinlichkeitsverteilung und mögliche Schätzwerte	37
5.3	Der Bayes'sche Filteralgorithmus und seine Varianten	39
5.4	Systemmodell im Zustandsraum	40
5.5	Jordan-Normalform des Prozessmodells	41
5.6	Lineare und nichtlineare Transformation einer Normalverteilung	45
5.7	Multimodell-Schätzfiltervarianten	50
5.8	Schätzvorgang des Partikelfilters	51
5.9	Vergleich Schätzung EKF / UKF	52
5.10	Grundlegender Ablauf Objekttracking	54

5.11	Elliptisches Ähnlichkeitsmaß	55
5.12	Datenzuordnung und ihre Varianten	56
5.13	Definition Umfeldkarte in 2D	58
5.14	Ablaufstrategien der Objektfusion	68
6.1	Konzept der lokalen Objektkarte	72
6.2	Objektmodell auf Basis lokaler Karten	74
6.3	Koordinierte Kreisfahrt mit konstanter Kurswinkelgeschwindigkeit	75
6.4	Einfluss der Drehung auf die Konturpunkte	76
6.5	Sensordaten der objektgebenden Umfeldsensorik	79
6.6	Prinzip der Datenassoziation	82
6.7	Architektur der urbanen Objektverfolgung	83
6.8	Mehrdeutige Abbildung einer Punktwolke	89
6.9	Freiform-Tracking bei idealer Ebene-2-Assoziation	95
6.10	Freiform-Tracking bei zufällig gestörter Ebene-2-Assoziation	96
6.11	Freiform-Tracking bei systematisch gestörter Ebene-2-Assoziation	97
6.12	Plausibilisierungszonen zur Trackinitialisierung	100
6.13	Plausibilisierung gegen das vertikale Fahrbahnprofil	101
7.1	Ergebnis der kartenbasierten Befahrbarkeitsanalyse	103
7.2	Informationsebenen und Datenfluss	105
7.3	Fahrzeugfeste Kartendarstellung	106
7.4	Ortsfeste Kartendarstellung	107
7.5	Von Neumann-Rechnerarchitektur	108
7.6	Speicherlayout für optimierten Datenzugriff	109
7.7	Datendurchsatz der Karte über Anzahl der Teilgitter	109
7.8	Ringförmig verkettete Karte in Blockstruktur	110
7.9	Eintragestrategie der LIDAR-Daten	111
7.10	Raytracing-Algorithmus nach Bresenham	112
7.11	Vergleich verschiedener Programmiermuster	117
7.12	Expand-Algorithmus	118
7.13	Gradientenbasiertes probabilistisches Sensormodell	123
7.14	Ergebnisse der Farbanalyse	127
7.15	Projektion auf die Kartenebene	128
7.16	Eintragen der farbbasierten Klassifikation	129
7.17	Farbbasiertes probabilistisches Sensormodell	130
8.1	Erprobungsgelände Team CarOLO	133
8.2	Versuchsaufbau für Szenario 1	135
8.3	Verlauf von Position und Geschwindigkeit in Szenario 1	136
8.4	Verlauf von Kurswinkel und Beschleunigung in Szenario 1	136
8.5	Versuchsaufbau für Szenario 2	137
8.6	Verlauf von Position und Geschwindigkeit in Szenario 2	137
8.7	Verlauf von Kurswinkel und Beschleunigung in Szenario 2	138
8.8	Versuchsaufbau für Szenario 3	139
8.9	Positionsverlauf in Szenario 3	139

8.10	Geschätzte Geschwindigkeit und Beschleunigung in Szenario 3	140
8.11	Geschätzter Kurswinkel und Kurswinkelgeschwindigkeit in Szenario 3	140
8.12	Testumgebung Szenario 1	141
8.13	Eingangsdaten Szenario 1	142
8.14	Zwischendaten Szenario 1	142
8.15	Befahrbarkeit Szenario 1	143
8.16	Ergebnisse Datenfusion	143
8.17	Szenario 2	144
8.18	Eingangsdaten Szenario 2	144
8.19	Zwischendaten Szenario 2	145
8.20	Befahrbarkeit Szenario 2	145
8.21	Ergebnisse Datenfusion	146
8.22	Szenario 3	146
8.23	Eingangsdaten Szenario 3	147
8.24	Zwischendaten Szenario 3	147
8.25	Befahrbarkeit Szenario 3	148
8.26	Ergebnisse Datenfusion	148
8.27	Halbfinal-Testareale Urban Challenge 2007	150
8.28	Qualifikationslauf A	151
8.29	Absperrungen in Qualifikationslauf A	151
8.30	Herausforderung in Qualifikationslauf A	152
8.31	Qualifikationslauf B	153
8.32	Startzone im Qualifikationslauf B	153
8.33	Innenaufnahme Überholvorgänge und Engstellen im Qualifikationslauf B	154
8.34	Freifahrtzonen im Qualifikationslauf B	155
8.35	Übersicht Qualifikationslauf C	155
8.36	Kreuzungssituation und Straßenblockade in Qualifikationslauf C	156
8.37	Übersicht Finale	157
8.38	Kursverlauf bis Planungsfehler	159
8.39	Kursverlauf ab Planungsfehler	160
8.40	Zufahrt zum Parkbereich und Fehlerursache	161
A.1	Koordinatensysteme für Umfelderkennung	170
A.2	Verzerrungen der polykonischen Kartenprojektion	172
A.3	Diskretes Koordinatensystem der kartenbasierten Darstellung	174
A.4	Kamerakoordinatensystem	175
A.5	Extrinsische Kamerakalibrierung	176
B.1	Vollständige Systemarchitektur	178

Symbolverzeichnis

Lateinische Symbole

2^Ω	Potenzmenge des Wahrscheinlichkeitsraumes Ω
a	Betrag der Objektbeschleunigung
B	Befahrbarkeit
$bl[A]$	kummuliertes Dempster-Shafer Vertrauen in A
C	Dempster-Shafer Konflikt
d	allgemein Abstand
\mathbf{d}	allgemein Richtungsvektor
$d(a, b)$	Distanzmaß zwischen a und b
\mathbf{e}	vektorieller Fehlerterm
$E[A]$	Erwartungswert von A
f	Farbähnlichkeit im Wertebereich 0 bis 1
$f(\mathbf{x}_k, \mathbf{u}_k)$	Diskrete Systemübertragungsfunktion
\mathbf{F}	Lineare Systemmatrix oder linearisierte Systemübertragungsfunktion
g	Gradient der Höhenkarte
h	Höhenmesswert
$h(\mathbf{x})$	Ausgangsgleichung des Zustandsvektors \mathbf{x}
\mathbf{H}	Lineare Ausgangsmatrix oder linearisierte Systemübertragungsfunktion
i, j	diskrete Koordinaten einer Kartendarstellung
K	Ungewissheit
\mathbf{K}	Matrix der Kalmanverstärkung
$l[z]$	Log-Odd Rate einer Zellbelegung
$m[A]$	allgemeine Dempster-Shafer Wahrscheinlichkeitsmasse des Ereignis A
\mathbf{n}	Ebenen-Normalenvektor
$N[\mathbf{x}, \boldsymbol{\mu}, \mathbf{P}]$	Normalverteilung mit Mittelwert $\boldsymbol{\mu}$ und Varianz \mathbf{P}
\mathbf{p}	Ortsvektor eines beliebigen Punktes
$p(\mathbf{x})$	Wahrscheinlichkeitsdichtefunktion des Vektors \mathbf{x}
\mathbf{P}	Kovarianzmatrix des Systemzustandes

$P[A]$	Wahrscheinlichkeit des Ereignis A
$pl[A]$	kumulierte Dempster-Shafer Plausibilität von A
\mathbf{r}	Messrauschvektor
\mathbf{R}	Kovarianzmatrix des Messrauschens
\mathbf{q}	Systemrauschvektor
\mathbf{Q}	Kovarianzmatrix des Prozessrauschens
t	Zeitstempel
\mathbf{S}	Kovarianzmatrix der Innovation
\mathbf{t}	allgemeiner Translationsvektor
T	Abtastzeit eines zeitdiskreten Systems
\mathbf{T}	allgemeine Matrix für Koordinatentransformation
\mathbf{u}	Eingangsvektor
U	Unbefahrbarkeit
v	Betrag der Geschwindigkeit eines Objektes
$Var[A]$	Varianz von A
w	allgemeines skalares Gewicht
x, y, z	x,y,z-Position eines Objekts
\mathbf{x}	Zustandsvektor
\mathbf{x}^*	Vorhersage des Zustandsvektors \mathbf{x}
$\hat{\mathbf{x}}$	Schätzwert des Zustandsvektors \mathbf{x}
\mathbf{y}	Messvektor
\mathbf{y}^*	Vorhersage des Messvektors
\mathbf{Y}_k	Satz aller Messungen bis zum Zeitpunkt k
z	allgemein Zelle einer Karte
$z(i, j)$	Die Zelle einer Karte an der Stelle (i,j)
\mathbf{Z}	Gesamtheit aller Zellen eines kartenbasierten Umfeldmodells

Griechische Symbole

α	Winkel (allgemein)
χ	Sigma-Punkt Realisierung des Zustandsvektors
δ_l	Lenkwinkel
$\dot{\delta}_l$	Lenkwinkelgeschwindigkeit
γ	Sigma-Punkt Realisierung des Messvektors
Γ	einheitlicher Zustandsraum des kartenbasierten Umfeldmodells
ι	Normierungsterm

μ	Mittelwert einer mehrdimensionalen Normalverteilung
ϕ	Kurswinkel eines Objektes
$\dot{\phi}$	Kurswinkelgeschwindigkeit eines Objektes
Φ	Rollwinkel des eigenen Fahrzeugs
$\dot{\Phi}$	Rollrate des eigenen Fahrzeugs
Ψ	Gierwinkel des eigenen Fahrzeugs
$\dot{\Psi}$	Gierrate des eigenen Fahrzeugs
σ	Standardabweichung
Θ	Nickwinkel des eigenen Fahrzeugs
$\dot{\Theta}$	Nickrate des eigenen Fahrzeugs
Θ	Zuordnungsereignis

Indizes

B	Kamerakoordinaten
F	Fahrzeugkoordinatensystem
FS	Transformation vom Sensor- ins Fahrzeugkoordinatensystem
k	Gültigkeit zum Zeitpunkt $k \cdot T$
P	Pixelkoordinaten
S	Sensorkoordinatensystem
W	Weltkoordinatensystem
WF	Transformation vom Fahrzeug- ins Weltkoordinatensystem
x	X-Komponente
y	Y-Komponente
z	Z-Komponente
$z(i, j)$	Gültigkeit in Zelle (i,j) des kartenbasierten Umfeldmodells

1 Übersicht

Die vorliegende Arbeit beschreibt ein System zur autonomen Fahrzeugführung in urbaner Umgebung. Der Schwerpunkt liegt auf der Kombination objekt- und kartenbasierter Umfeldmodelle zur Umgebungserfassung sowie darüber hinaus auf der Systemarchitektur zur Realisierung der automatischen Fahrfunktion. Den Rahmen für die Entstehung dieser Arbeit bildet die Teilnahme an der DARPA Urban Challenge durch die TU-Braunschweig im Jahr 2007.

Nach einer Einleitung und Motivationsgebung in Kapitel 2 erfolgt in Kapitel 3 eine Einführung in die Anforderungen des Wettbewerbes sowie eine kurze Übersicht über den aktuellen Stand der Technik auf den Gebieten Umfeldwahrnehmung und automatische Fahrzeugführung.

Kapitel 4 behandelt ausführlich die entwickelte Fahrzeugarchitektur. Diese ist unterteilt in vier Funktionsebenen zur Wahrnehmung, Situationsinterpretation, Aktionsplanung und Ausführung sowie eine weitere Ebene zur Systemüberwachung.

In Kapitel 5 werden die theoretischen Grundlagen für eine maschinelle Erfassung und Modellierung der Fahrzeugumgebung behandelt. Dabei wird auf das Prinzip der Objektverfolgung sowie der kartenbasierten Umfeldwahrnehmung und die hierfür notwendigen Algorithmen eingegangen.

In Kapitel 6 erfolgt daraus abgeleitet die Konzeption einer urbanen Objektverfolgung. Für die Wahrnehmung unstrukturierter Hindernisse wird das Objektmodell durch eine Freiformdarstellung auf Basis lokaler Karten erweitert. Als Gegenstück hierzu wird in Kapitel 7 eine kartenbasierte Modellierung der Befahrbarkeit als Indiz für den urbanen Straßenverlauf entwickelt. Beide Komponenten sind Teil eines hybriden Umfeldmodells und stehen miteinander in Austausch.

In Kapitel 8 wird die Leistungsfähigkeit des hybriden Umfeldmodells evaluiert und das Verhalten des Gesamtsystems am Beispiel des Urban Challenge Wettbewerbes diskutiert.

Die Arbeit schließt mit einer Zusammenfassung sowie dem Ausblick in Kapitel 9. Aufbauend auf den Wettbewerbserfahrungen wird hier insbesondere auf mögliche Schritte zur Weiterentwicklung des Fahrzeugsystems eingegangen.

2 Einleitung und Motivation

Die Vision einer fahrerlosen Fahrt im allgemeinen Straßenverkehr fasziniert Techniker wie auch Nicht-Techniker bereits seit der Frühphase des Automobils. Der enorme technische Fortschritt in der letzten Hälfte des vergangenen Jahrhunderts und die sich damit ergebenden Möglichkeiten führten zu einer Vielzahl von Forschungsprojekten in diesem Kontext. Erste automatische Fahrversuche wurden hierbei bereits in den 70er Jahren von den Tsukuba-Laboratorien in Japan demonstriert. In den 80er Jahren konnte eine Forschergruppe um Prof. Ernst Dickmanns in München die vollautomatische Fahrt auf abgesperrten Straßen mit Geschwindigkeiten bis zu 100 km/h realisieren. Nicht zuletzt diese Erfolge führten zu einer Förderung des Forschungsfeldes durch die Europäische Union. Im Rahmen des Förderprojekts Prometheus (1987-1995) konnte ein automatischer Fahrbetrieb auf einer öffentlich zugänglichen Autobahn mit Geschwindigkeiten bis zu 180 km/h realisiert werden, besonders herausragend waren dabei Demonstrationsfahrten von München nach Paris und Odense (Dänemark). Auch wenn dabei noch vergleichsweise häufig menschliche Eingriffe in den automatischen Fahrbetrieb notwendig waren (im Mittel ca. alle 9 Kilometer), so wurde die prinzipielle Machbarkeit dargestellt. In den Jahren 1997 bis 2000 wurde durch die Volkswagen AG und die TU-Braunschweig eine vollständig automatische Fahrt zur Optimierung der Fahrzeugerprobung dargestellt.

Auch wenn eine umfassende alltagstaugliche Realisierung des automatischen Fahrbetriebes im öffentlichen Straßenverkehr bis heute noch nicht absehbar ist, so führten die Aktivitäten zu enormen Fortschritten in den Bereichen Fahrzeugführung-/Regelung, Sensorik und Umfeldwahrnehmung. Diese Fortschritte bildeten dabei eine Grundlage für die Auskopplung diverser Fahrerassistenz- und Sicherheitssysteme, welche bereits ihren Einzug in heutige Serienkraftfahrzeuge erhalten haben. Als Beispiele seien an dieser Stelle das elektronische Stabilitätsprogramm (Einführung im Jahre 1995), die automatische Abstandsregelung (Einführung im Jahre 1998), der Spurwechselassistent (Einführung im Jahre 2007) oder auch Systeme für das (teil-)automatische Einparken (z.B. Parklenkassistent, Einführung durch Volkswagen im Jahre 2007) genannt.

Die Entwicklung auf diesem Gebiet wird durch eine Vielzahl nationaler und internationa-

ler Forschungsaktivitäten begleitet, exemplarisch seien an dieser Stelle die aktuell laufenden Projekte AKTIV (Adaptive und Kooperative Technologien für den Intelligenten Verkehr [2]), das EU-Förderprojekt Intersafe-2 (Cooperative Intersection Safety [65]) sowie das im Jahr 2007 beendete EU-Forschungsvorhaben Prevent (Preventive and Active Safety Applications [103]) genannt.

Sowohl das automatische Fahren als auch fortschrittliche Fahrerassistenzsysteme, die Unterstützung auf der Manöverebene des Fahrzeugs anbieten [52], setzen eine maschinelle Wahrnehmung und Interpretation des Fahrzeugumfelds zur Planung oder Bewertung der Fahrmanöver voraus. Es zeigt sich hierbei als eine wesentliche Einschränkung aktueller Systeme, dass diese für den Einsatz im wenig komplexen außerstädtischen Umfeld entwickelt worden sind. Eine Übertragung in innerstädtische Szenarien scheitert bislang an der Komplexität und Variabilität der Umgebung. Die Realisierung einer konsistenten künstlichen Situationswahrnehmung im Stadtbereich ist daher eine der wesentlichen Herausforderungen für das Forschungsfeld im Laufe der nächsten Jahre.

In diesem Kontext haben sich die durch die amerikanische Regierung geförderten DARPA-Challenges als Triebfeder für Weiterentwicklung hin zu komplexeren Einsatzumgebungen entwickelt.

“It shall be a goal of the Armed Forces to achieve the fielding of unmanned, remotely controlled technology such that... by 2015, one-third of the operational ground combat vehicles are unmanned” [98]

Ausgelöst durch diesen Beschluss des US-Kongresses im Jahre 2001 setzten die Wettbewerbe in den Jahren 2004 und 2005 die fahrerlose Fahrt im Offroad-Bereich (Wüste) und schließlich im Jahre 2007 die autonome Fahrt im Stadtverkehr als Ziel. Die notwendige Interaktion autonomer Fahrzeuge im komplexen urbanen Umfeld sowie die mit dem Wettbewerb verbundene Signalwirkung und große Sichtbarkeit entfachen seitdem eine hohe Innovationskraft auf dem Forschungsgebiet. Der Wettbewerb entwickelt sich somit zu einer Demonstration des aktuell technisch Machbaren.

Diese Dissertation behandelt die Fahrzeugarchitektur sowie die darin enthaltene maschinelle Umfeldwahrnehmung für eine autonome Fahrt in komplexer urbaner Umgebung und basiert zu wesentlichen Teilen auf den Erfahrungen der Urban Challenge Teilnahme durch die TU-Braunschweig, angetreten unter dem Namen Team CarOLO (vgl. Abb. 2.1). Für die Wettbewerbsteilnahme wurde in einem interdisziplinären Team bestehend aus über 30 Mitarbeitern, fünf Instituten und drei Fachbereichen im Zeitraum zwischen den Jahren 2006 und 2007 das autonome Fahrzeug Caroline entwickelt. Das Fahrzeug konnte sich im Rahmen des Wettbewerbsverlaufs aus einem Feld von anfangs über 100 Teilnehmern für den Finallauf der

besten elf qualifizieren und ging als bester europäischer Beitrag aus dem Rennen hervor.



Abb. 2.1: Team CarOLO, Finale DARPA Urban Challenge, November 2007

3 Anforderungen und Stand der Technik

Die autonome Fahrzeugführung im urbanen Umfeld stellt höchste Anforderungen an die Umfeldwahrnehmung, Selbstlokalisierung, Situationsinterpretation, Missions- und Bahnplanung sowie Fahrzeugregelung. Im Rahmen des Urban Challenge Wettbewerbes werden die Randbedingungen für die autonome Fahrt durch ein umfangreiches Regelwerk [29, 28] definiert. Dieses fasst die Anforderungen an die Versuchsträger zusammen und bildet somit die Grundlage für den Fahrzeug-Entwicklungsprozess im Rahmen dieser Arbeit. Für ein besseres Grundverständnis soll daher zunächst eine kurze Übersicht über die im Regelwerk definierten Szenarien und die daraus abzuleitenden Fahrzeugfunktionen gegeben werden.

3.1 Anforderungen der Urban Challenge

Die Einzelbestandteile des gegebenen Anforderungskataloges lassen sich im Wesentlichen in vier Hauptkategorien einteilen:

- Der Bereich der grundlegenden Navigation umfasst einfaches Spurhalten sowie Ausweichmanöver, um Kollisionen mit statischen Hindernissen in der eigenen Fahrspur zu vermeiden (Abb. 3.1a). Der Versuchsträger muss fähig sein, dem Straßenverlauf entlang einer beliebig vorgegebenen GPS-Wegpunktliste zu folgen. Im Falle von Hindernissen auf der eigenen Fahrspur ist ein Ein- und Ausschervorgang mit ausreichendem Sicherheitsabstand vorzunehmen. Ist die Fahrbahn vollständig blockiert, so ist ein Wendemanöver (U-Turn) durchzuführen.
- Im Bereich der grundlegenden Interaktion gilt es, einfache Vorfahrtsregelungen zu beachten. In Kreuzungen wird das amerikanische First-In-First-Out Prinzip (4-way stop, Abb. 3.1b) angewendet. Demnach ist es für jedes Fahrzeug notwendig, zunächst an der Haltelinie einer Kreuzung zu halten. Vorfahrtsberechtigt ist das zuerst eintreffende Fahrzeug.




Abb. 3.1: Grundlegende Fahranforderungen

- Die weiterführende Navigation erfordert von den Fahrzeugen die Fähigkeit, eine beliebige, durch Hindernisse verstellte Freifläche zu durchfahren. Darüber hinaus sind Einparkvorgänge in definierten Parkzonen vorzunehmen (Abb. 3.2a). Im Falle von vollständig blockierten Streckenabschnitten ist zudem eine Ausweichroute selbstständig zu ermitteln. Die sichere Fahrzeugführung muss auch bei zeitweisem Ausfall der Satellitenortung gewährleistet sein.
- Die Kategorie der weiterführenden Interaktion setzt eine Berücksichtigung fließenden Verkehrs voraus. Bei Einfädel- oder Abbiegemanövern ist eine ausreichend große Zeitlücke einzuhalten (Abb. 3.2b), um eine Behinderung oder Gefährdung auszuschließen. Prinzipiell ist eine defensive Fahrweise darzustellen, im Falle drohender Kollisionen ist eine sofortige Notbremsung auszuführen.

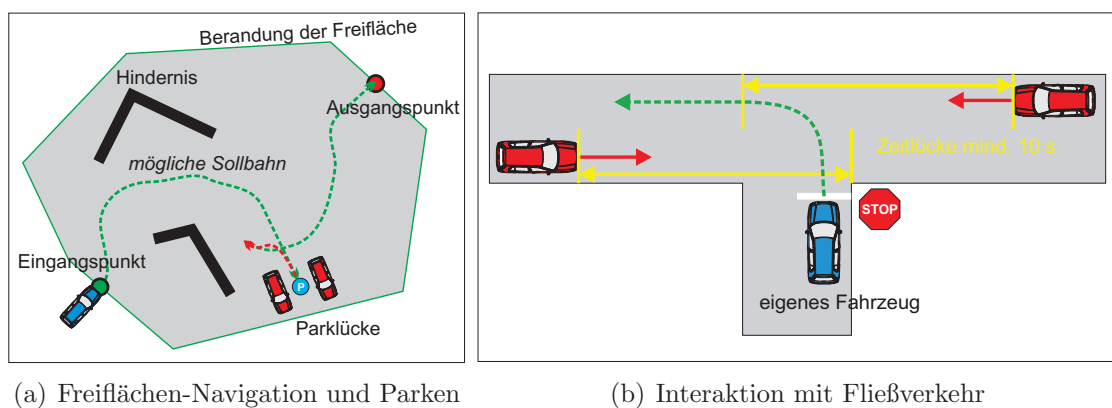


Abb. 3.2: Weiterführende Fahranforderungen

Im Rahmen des Wettbewerbes werden die Versuchsträger weitgehend unüberwacht und ohne die Möglichkeit eines korrigierenden menschlichen Eingriffs betrieben. Die Anbindung einer

drahtlosen Notaus-Vorrichtung ermöglicht einen sofortigen Halt zu jedem Zeitpunkt, Eingriffe in das Fahrzeug können jedoch zum sofortigen Ausscheiden aus dem Wettbewerb führen.

Auch wenn das skizzierte Regelwerk im Detail einigen Interpretationsspielraum zulässt, so können daraus einige grundlegende Anforderungen an das autonome Fahrzeug abgeleitet werden.

- Der autonome Fahrbetrieb erfordert eine vollständig elektronische Ansteuerung der gesamten Fahrzeugaktuatorik bestehend aus Gas, Bremse, Lenkung und Schaltung/Gangwahlhebel.
- Die Berücksichtigung der in den Missionsparametern gegebenen GPS-Wegpunkte erfordert den Einsatz einer Ortungsplattform mit hoher Präzision (Genauigkeit im Zentimeterbereich). Die Fähigkeit zur Behandlung von temporären GPS-Ausfällen, welche absichtlich oder durch die urbane Bebauung verursacht sein können, macht ferner den Einsatz eines Koppel-Navigationssystems zur Stützung der GPS-Position notwendig.
- Insbesondere im Bereich von Kurven ist eine simple Interpolation zwischen den gegebenen GPS-Wegpunkten nicht ausreichend. Das Spurhalten erfordert daher eine maschinelle Wahrnehmung der Fahrbahn sowie deren Abgrenzung von Hindernissen oder dem Fahrbahn-Randbereich.
- Die Interaktion mit fließendem Verkehr erfordert eine zuverlässige Modellierung aller bewegten Objekte im Aktionsbereich des Versuchsträgers. Das Einhalten von Zeitlücken und Sicherheitsabständen sowie die Interpretation von Kreuzungssituationen erfordert neben der Beschreibung ihrer Relativposition auch die Bestimmung der Geschwindigkeit bzw. des Kurses in Bezug auf das eigene Fahrzeug. Es ergibt sich die Notwendigkeit einer Objektbildung und Objektverfolgung.
- Die Interaktion mit stationären Hindernissen im Bereich von Freiflächen, Parklücken, am Fahrbahn-Randbereich oder im Falle blockierter Streckenabschnitte erfordert die Fähigkeit einer flexiblen Objektbeschreibung, um die Abbildung komplexer Strukturen zu ermöglichen. Die Wahrnehmung dieser unstrukturierten Umfeldbestandteile unterscheidet sich damit wesentlich von bisherigen Systemen zur Umgebungserfassung im Bereich der Fahrerassistenz.
- Das Erkennen von blockierten Streckenabschnitten erfordert einen Abgleich des zur Verfügung gestellten digitalen Kartenmaterials (GPS-Wegpunktliste) mit dem durch bordeigene Mittel erzeugten Umfeldmodell. Es ergibt sich die Notwendigkeit zur Georeferenzierung der Umfelddaten.

- Die Notwendigkeit zur Ausführung beliebiger Vor-, Rückwärts- und Parkmanöver erfordert ein Blickfeld von 360 Grad im direkten Nahfeld. Darüber hinaus gilt es, für das sichere Ausführen der geforderten Abbiege- und Ausschermanöver eine ausreichende Abdeckung und Reichweite der Sensorik in den Seitenbereichen sowie nach vorne und hinten sicherzustellen.
- Die Bahnplanung des Fahrzeugs muss in der Lage sein, selbstständig auf Basis des gegebenen Kartenmaterials unter Berücksichtigung der Umfelddaten einen optimalen Pfad von der aktuellen Ist-Position zum nächsten Missionsziel zu ermitteln. Ist ein Teilstrecke der ursprünglich geplanten Bahn blockiert, muss selbstständig eine Alternativroute ermittelt werden.
- Die fehlende Möglichkeit eines menschlichen Eingriffs im Wettbewerbsverlauf stellt hohe Anforderungen an die Langzeit-Robustheit des Systems.

3.2 Stand der Technik

Aus dem Bereich der Fahrerassistenz sowie der Robotik lassen sich eine Reihe von Komponenten und Methoden für die Realisierung des automatisch fahrenden Fahrzeugs ausnutzen, über die ein kurzer Überblick gegeben werden soll.

3.2.1 Sensorik zur Umfeldwahrnehmung

Im wesentlichen sind derzeit drei verschiedene Messprinzipien für die Umfeldwahrnehmung am Markt verfügbar.

- Radar-Sensoren finden sich in modernen Kraftfahrzeugen für die Umsetzung einer automatischen Abstandsregelung und Spurwechselassistenten. Unabhängig von den unterschiedlichen Sensortypen hinsichtlich Frequenzbereich, Modulationsverfahren oder Antennenaufbau lassen sich als fundamentale Messgrößen der Radarsysteme die Laufzeit und Dopplerverschiebung des Signals akquirieren. Diese sind proportional zum Abstand bzw. zur Relativgeschwindigkeit eines erfassten Ziels. Der für eine Ortsauflösung zusätzlich benötigte Erfassungswinkel zum Ziel kann über Antennen mit hoher Richtwirkung, Triangulation zwischen mehreren Sensoren oder beim Monopulse-Verfahren über die Auswertung der Phasendifferenz mehrerer Empfangsantennen bestimmt werden. Eine gute Übersicht über gängige Auswerteverfahren sowie aktuelle Weiterentwicklungen liefern [87, 88, 53, 54, 72].

Bedingt durch das Messprinzip wird eine hohe Entfernungs- und Geschwindigkeitsauflösung erzielt, während die Güte des Erfassungswinkels und damit verbunden die Ortsauflösung vor allem auch durch das unbekannte und über die Erfassungsdauer hinweg selten konstante Reflexionszentrum der Radarwelle am Zielobjekt beeinträchtigt wird. Üblich ist daher eine punktförmige Zieldarstellung, die keine Rückschlüsse über Form oder Ausdehnung des Ziels zulässt.

- LIDAR-Sensoren wurden schon früh als Alternative zur kostenintensiven Radartechnik evaluiert [70, 69, 43] und gewinnen zunehmend an Popularität. Zur Wahrnehmung des Umfeldes werden diskrete Laser-Pulse im infraroten Spektrum in die Umgebung ausgesandt und an Zielobjekten reflektiert. Mithilfe einer Empfängereinheit werden die Reflexionen erfasst und die Entfernung zum Ziel auf Basis einer Licht-Laufzeitmessung bestimmt. Im Gegensatz zum Radar ist der LIDAR-Puls scharf fokussierbar, so dass sich in Verbindung mit der bekannten Strahlgeometrie eine hohe Ortsauflösung ergibt. Eine Messung der Relativgeschwindigkeit ist nicht möglich, so dass diese aus der Differenzierung aufeinander folgender Abstands-Messwerte erfolgen muss.

Zu unterscheiden sind feststehende und rotierende LIDAR-Systeme. Bei feststehenden Sensoren wird die Abtastung eines größeren Beobachtungsbereiches über die Anordnung mehrerer Sende-/Empfangseinheiten unterschiedlicher Ausrichtung im Sensor realisiert (Mehrstrahl-LIDAR). Die Ortsauflösung ist hierbei durch die Aufteilung der Einheiten und die Divergenz des Laserpulses bestimmt. Bei rotierenden LIDAR-Systemen wird der Lichtpuls über eine drehbare Spiegeleinheit abgelenkt, wodurch ein kontinuierliches Abtasten des Umfeldes ermöglicht wird.

Die hohe Ortsauflösung ermöglicht eine Messung von Objektkonturen, wodurch sich gegenüber Radar-Sensoren ein deutlicher Informationsgewinn für die automatische Fahrzeugführung ergibt. Als problematisch im praktischen Einsatz erweist sich die fehlende vertikale Auflösung bei Einebenen-Lidarsystemen. In Verbindung mit üblichen Nickbewegungen des Fahrzeugaufbaus erschwert dies die Unterscheidung von tatsächlichen Hindernissen und unerwünschten Reflexionen von der Fahrbahnebene. Neuartige LIDAR-Systeme [125] streben eine Erhöhung der Anzahl unabhängiger Erfassungsebenen an, wodurch analog zum Mehrstrahl-LIDAR eine vertikale Abstandsinterpretation ermöglicht wird.

- Kamerasysteme erleben gegenwärtig einen regelrechten Boom bezüglich ihres Einsatzes im Automobil. Erste praktische Applikationen finden sich im Bereich Fahrspurdetektion, Rückfahrhilfe, Parkassistentz und Verkehrszeichenanzeige. Aufgrund der reichhaltigen Bildinformation ist für die Zukunft mit einem weiter anwachsenden Applikationsportfolio in puncto bildbasierter Umfeldwahrnehmung zu rechnen.

Da auf Basis des Kamerasystems nur ein zweidimensionales Abbild der Fahrzeugumgebung zur Verfügung steht, existieren verschiedene Ansätze zur Rekonstruktion der dreidimensionalen Zusammenhänge [122].

- Modellbasierte Verfahren treffen Grundannahmen über Form und Größe bekannter Objekte im Fahrzeugumfeld und erzielen die dreidimensionale Umfeldrekonstruktion über den Skalierungsfaktor der Objekte im Bild. Für die hierzu notwendige Objekterkennung wird auf Standard-Bildverarbeitungsalgorithmen zur Merkmalsextraktion [46] und moderne Klassifikatoren [68] zurückgegriffen.
- Alternativ hierzu wird im Rahmen der Stereoskopie über das Prinzip der Korrespondenz auf Basis von Aufnahmen aus verschiedenen Blickrichtungen die Lage eines Bildpunktes in 3D trianguliert. Aktuelle Systeme streben eine möglichst dichte Tiefenkarte der Fahrzeugumgebung an [48], durch Kombination mit dem optischen Fluss zeitlich folgender Aufnahmen lässt sich ferner eine kombinierte Positions- und Geschwindigkeitsschätzung der Bildpunkte vornehmen [47], wodurch sich Vorteile bei der nachgeschalteten Objektbildung und -verfolgung ergeben. Steht nur eine Kamera zur Verfügung, lassen sich die Ansätze der Stereoskopie bei statischem Umfeld und bewegter Fahrzeugplattform auf die Auswertung zeitlich aufeinander folgender Aufnahmen erweitern [58].
- Aktuell rückt neben LIDAR-Sensoren und passiven Kamerasystemen eine Mischform beider Technologien in den Fokus der Automobilindustrie. Bei sogenannten PMD-Kameras (Photonic Mixer Device) wird die Szenerie mit einer modulierten Infrarot-Lichtquelle ausgeleuchtet und aus der Phasenverschiebung des in die Kamera reflektierten Lichtes auf die Laufzeit bzw. die Entfernung zurückgerechnet [95, 109]. Durch die Verwendung einer amplitudenmodulierten Lichtquelle und die damit verbundene Störempfindlichkeit sowie die vergleichsweise kostenintensiven Lichtquellen und Kameraschips ist ein Serieneinsatz dieser Technologie derzeit noch ungeklärt.

Im Bereich der Parkapplikation sind ferner ultraschallbasierte Messgeber Stand der Technik. Aufgrund der mit dem Ultraschall verbundenen geringen Reichweite und Auflösungsfähigkeit soll auf diese hier jedoch nicht näher eingegangen werden.

3.2.2 Umfeldmodellierung und Datenfusion

Von nicht geringerer Bedeutung als die physikalische Messgrößenerfassung ist die Auswertung, Interpretation und Modellierung der Sensordaten im Rahmen des Umfeldmodells. Die

in der Literatur beschriebenen Verfahren lassen sich im Wesentlichen in zwei unterschiedliche Konzepte aufteilen:

- Im Bereich der Automobiltechnik ist das objektbasierte Umfeldmodell Stand der Technik. Die reale Fahrzeugumgebung wird stark vereinfacht und auf eine geringe Anzahl relevanter Objekte (z.B. fremde Fahrzeuge) reduziert. Für die Objekte wird ein simples Objektmodell vorgegeben. Dieses wird durch den Einsatz klassischer Zustandsschätzverfahren [7, 81] im Rahmen des sog. Objekt-Trackings [16, 17] aus den zur Verfügung stehenden Messdaten rekonstruiert. Die Gesamtheit aller Objekte (Objektliste) bildet das Umfeldmodell, auf dessen Basis alle übergeordneten Interpretationsaufgaben erfolgen.

Die Dimension der Objekt-Zustandsvektoren bestimmt die Komplexität des Umfeldmodells und somit den Grad der Vereinfachung. Als praktisches Beispiel sei die punktzelförmige Darstellung von vorausfahrenden Fahrzeugen im Rahmen der automatischen Distanzregelung genannt. Eine Erweiterung der Tracking-Verfahren auf die multisensorielle Objektverfolgung ist in [45, 12, 114] ausführlich beschrieben.

Für die Zustandsschätzung erweist sich vor allem die Zuordnung der eingehenden Messdaten zu den Objekthypothesen des Umfeldmodells als herausfordernd. Kommt es zu falschen oder fehlenden Zuordnungen, wird die Qualität der Zustandsschätzung unabhängig vom eingesetzten Schätzalgorithmus negativ beeinflusst. Aktuelle Forschungsarbeiten [84, 85] beschäftigen sich daher mit der gleichzeitigen Schätzung einer Objekt-Existenzwahrscheinlichkeit, die als quantitatives Gütemaß für die Verlässlichkeit des Umfeldmodells herangezogen werden kann.

- Im Bereich der mobilen Robotik hat sich ein kartenbasiertes Umfeldmodell zur Bahnplanung etabliert [32, 117, 120, 129]. Im Gegensatz zur objektbasierten Darstellung wird im Rahmen einer digitalen Umfeldkarte die gleichmäßige Beschreibung der gesamten Fahrzeugumgebung angestrebt, wobei eine explizite Modellierung der Freibereiche zwischen den Hindernissen erfolgt. Das Umfeld wird in eine Menge gleichartiger Zellen zerlegt, welche jeweils stellvertretend für einen kleinen Ausschnitt der realen Umgebung stehen. Der Grad der Detaillierung wird durch die Auflösung der Karte sowie den Informationsgehalt der einzelnen Zellen (Merkmalsraum) festgelegt. Ein klassisches Beispiel für die kartenbasierte Umfelddarstellung ist das Prinzip der Belegungsgitter (engl. Occupancy Grids) [41]. Der Merkmalsraum ist in diesem Fall binär, so dass lediglich zwischen freien und belegten Zellen unterschieden wird. Auf Basis dieser Darstellung lassen sich eine Reihe verschiedener Algorithmen zur robotischen Bahnplanung effizient umsetzen.

Nicht zuletzt durch den erfolgreichen Einsatz im Rahmen der DARPA Grand Chal-

lenge im Jahre 2005 [118, 121] gewinnt die kartenbasierte Modellierung zunehmend an Popularität im Bereich Fahrerassistenz.

3.2.3 Bahnplanung

Steht das Umfeldmodell auf Basis einer maschinellen Umgebungserfassung zur Verfügung, so muss im Rahmen der autonomen Fahrt ein kollisionsfreier Pfad vom Start- zu einem gegebenen Zielpunkt bestimmt werden. Für die Wahl des Pfades gilt es, die Randbedingungen des Umfeldmodells, der Fahrdynamik sowie u.U. des Regelwerks zu berücksichtigen, wodurch sich die Komplexität der Bahnplanung deutlich erhöht. Die Aufgabe stellt sich unabhängig von der Zielsetzung analog in der allgemeinen Robotik, hierbei werden folgende Prinzipien zugrunde gelegt:

- Geht man von einem ebenen Umfeld aus, so spannt die autonome mobile Plattform mit den ihr zur Verfügung stehenden Freiheitsgraden (Position x und y sowie Orientierung Φ) einen dreidimensionalen Konfigurationsraum auf.
- Durch Abgleich mit dem Umfeldmodell lässt sich der Konfigurationsraum des Fahrzeugs (alle physikalisch möglichen Positionen / Orientierungen) abgrenzen in mögliche (sichere) und unmögliche (z.B. Konflikt mit Hindernis) Konfigurationen.
- Die physikalischen Zwangsbedingungen des Roboters (z.B. Wendekreis) legen den möglichen Übergang von einer Konfiguration in die nächste fest.
- Aufgabe der Bahnplanung ist es, einen Pfad durch den Konfigurationsraum des Roboters zu bestimmen, der zum einen den physikalischen Zwangsbedingungen genügt und zum anderen unmögliche Konfigurationen umgeht.

Es ist offensichtlich, dass der Schwierigkeitsgrad einer automatisierten Lösungsfindung mit der Dimension des Konfigurationsraumes exponentiell zunimmt. Generell werden hierzu folgende Methoden beschrieben [75]:

- Der Konfigurationsraum wird als Ganzes in Form eines Gitters diskretisiert, die Zwangsbedingungen legen die Möglichkeit des Übergangs von einer Gitterzelle zur nächsten fest (vgl. Abb. 3.3a). Eine Anwendung gängiger Suchalgorithmen (vgl. [30]) wird anschließend genutzt, um einen Pfad von einem beliebigen Start- zum Zielpunkt im Konfigurationsraum zu bestimmen.

- Alternativ dazu lässt sich ausgehend vom Startpunkt eine inkrementell vorwärts gerichtete Bahnplanung vornehmen, indem eine Reihe fahrphysikalisch möglicher Folge-trajektorien von der aktuellen Planungsposition aus erzeugt wird und diese mit den Zwangsbedingungen des Konfigurationsraumes abgeglichen werden. Eine Folgetrajektorie wird positiv gewichtet, wenn diese in Richtung des Zielpunkts führt und negativ, wenn eine Annäherung an Hindernisse erfolgt. Hindernisse üben somit eine abstoßende Kraft auf die geplante Sollbahn aus, der Zielpunkt eine Anziehung. Ausgewählt wird jeweils die Folgetrajektorie mit dem größten Gewicht (vgl. Abb. 3.3b). Aufgrund der Analogie zur Physik wird dieser Ansatz Potentialfeldmethode genannt.
- Die Potentialfeldmethode lässt sich optimieren (vgl. [116]), indem zu jedem Planungsschritt die möglichen Folgetrajektorien stochastisch erzeugt werden und rekursiv ein Suchbaum durch den Konfigurationsraum aufgespannt wird (vgl. Abb. 3.3c). Es wird in diesem Fall nicht nur die optimale Folgetrajektorie, sondern es werden alle Folgetrajektorien weiter verfolgt, bis ein gültiger Pfad zum Zielpunkt ermittelt werden konnte. Die Komplexität des Suchbaumes lässt sich begrenzen, indem unmögliche Konfigurationen zu einem Abbruch des entsprechenden Zweiges führen.




Abb. 3.3: Übersicht Bahnplanungskonzepte

Wenn ein gültiger Pfad durch den Suchbaum ermittelt werden kann, so stellt die zuletzt genannte vollständige stochastische Bahnplanung das Erreichen des Zielpunktes sicher. Im umgekehrten Fall ist jedoch keine Aussage darüber möglich, ob der Zielpunkt tatsächlich unerreichbar ist oder lediglich die Vorausplanung der Folgetrajektorien (Schrittweite des Bahnplaners) zu grob gewählt wurde. Durch die aufwendige Konstruktion des Suchbaumes ergibt sich zudem ein hoher Rechenzeitbedarf. Im Vergleich hierzu verursacht die einfache Potentialfeldmethode einen deutlich geringeren Rechenaufwand, läuft jedoch Gefahr, in lokalen Minima der für die Bewertung herangezogenen Kostenfunktionen und nicht im gewünschten

Zielpunkt zu enden.

Im hier diskutierten Anwendungsfall ist eine vollständige Diskretisierung des Konfigurationsraumes aufgrund dessen Größe und Dimension praktisch nicht umsetzbar, so dass vor allem die beiden zuletzt genannten Verfahren in Betracht kommen.

3.3 Übertragung auf den urbanen Bereich und Weiterentwicklungsbedarf

Für einen Einsatz in komplexer urbaner Umgebung weisen alle zum derzeitigen Stand der Technik verfügbaren Sensorsysteme sowie die im Einsatz befindlichen Umfeldmodelle und Bahnplanungskonzepte deutliche Defizite auf, so dass ein entsprechender Weiterentwicklungsbedarf besteht:

- Das im automobilen Umfeld übliche objektbasierte Umfeldmodell erzielt durch die Vorgabe simpler Objektmodelle eine hohe Datenreduktion und ermöglicht die Umsetzung in Echtzeit bei begrenzten Ressourcen. Es ist jedoch nicht oder nur bedingt geeignet, komplexe Hindernisse im Randbereich der Fahrzeugumgebung oder den urbanen Straßenverlauf korrekt wiederzugeben. Diese stehen mit der einfachen Modellvorgabe in Konflikt.
- Demgegenüber ist das kartenbasierte Umfeldmodell aus der Robotik zwar gut geeignet zur Beschreibung komplex strukturierter Hindernisse, scheitert jedoch bei der Berücksichtigung von dynamischen Veränderungen des Fahrzeugumfelds. Der Ansatz der Belegungskarten setzt ein statisches Umfeld voraus. Erweiterungen für dynamische Umgebungen sind zwar in der Literatur beschrieben [24, 25], scheitern jedoch in der praktischen Implementierung an dem enormen Rechenzeitbedarf ausgelöst durch die Multidimensionalität der Karte. Diese führt bereits bei der Anwendung klassischer Belegungsgitter für einen Einsatz im Automobil zu größeren Herausforderungen. Dies gilt insbesondere bei der Verwendung langreichweitiger Sensoren, welche die Aktualisierung eines entsprechend großen Kartenausschnitts erfordern.
- Die in der Literatur beschriebenen Algorithmen zur Bahnplanung gehen im Wesentlichen von einem statischen Fahrzeugumfeld aus. Ziel ist die Bestimmung eines kollisionsfreien Pfades durch den Konfigurationsraum. Eine Interaktion mit dynamischen Hindernissen im Fahrzeugumfeld und darüber hinaus die Berücksichtigung von zusätzlichen Regeln (z.B. Vorfahrt) sind dagegen bislang nicht vorgesehen.

Es zeigt sich, dass für eine Bewältigung des urbanen Umfeldes vor allem eine Kombination der bestehenden Ansätze erforderlich ist. Im Rahmen dieser Arbeit und der nächsten Kapitel wird auf die sich daraus ableitende Fahrzeugarchitektur sowie schwerpunkthaft auf die Weiterentwicklung der Umfeldwahrnehmung eingegangen. Objekt- und kartenbasierte Konzepte werden in einem hybriden Umfeldmodell parallel zum Einsatz gebracht, um so die Stärken beider Modelle für Teilaspekte der Fahrzeugführung nutzbar zu machen.

4 Architektur für die autonome Fahrzeugführung

Die Realisierung eines autonom fahrenden Fahrzeugs erfordert die interdisziplinäre Zusammenarbeit aus den Bereichen Informatik, Elektro- und Regelungstechnik, Sensorik und Umfeldwahrnehmung sowie Ortung und Navigation. Die Entwicklung einer leistungsfähigen und modularen Fahrzeugarchitektur zur Entkopplung der einzelnen Arbeitsgruppen sowie die frühzeitige Definition eindeutiger Schnittstellen sind Grundlage für eine erfolgreiche Funktionsumsetzung. Es ist in der Literatur [123, 121, 22] zu beobachten, dass unterschiedliche praktische Realisierungen für die automatische Fahrzeugführung stets zu einer Unterteilung in vier wesentliche Funktionsebenen führen, welche angelehnt am Vorbild des menschlichen Fahrers folgende Fragestellungen bedienen:

1. **Wahrnehmungsebene:**

Was geschieht um mich herum und wo befinde ich mich?

2. **Interpretationsebene:**

Welche Auswirkung hat das Umfeld auf mich und die notwendigen Entscheidungen zum Erreichen meines Ziels?

3. **Aktionsebene:**

Welche Möglichkeiten zur Reaktion habe ich und wie setze ich diese optimiert zum Erreichen des Ziels ein?

4. **Ausführungsebene:**

Wie bediene ich die mir zur Verfügung stehenden Aktoren, um die beabsichtigte Aktion korrekt auszuführen?

Überträgt man diese vier Ebenen auf ein technisches Gesamtsystem, so ergibt sich die in Abb. 4.1 dargestellte Fahrzeugarchitektur. In der Wahrnehmungsebene werden die Messdaten der verschiedenen Sensorsysteme im Rahmen einer zentralen Datenakquisition gesammelt und zur Weiterverarbeitung an die übergeordneten Module übermittelt. Die Daten der umfeld-erfassenden Sensorsysteme werden fusioniert und in ein zentrales Umfeldmodell überführt.

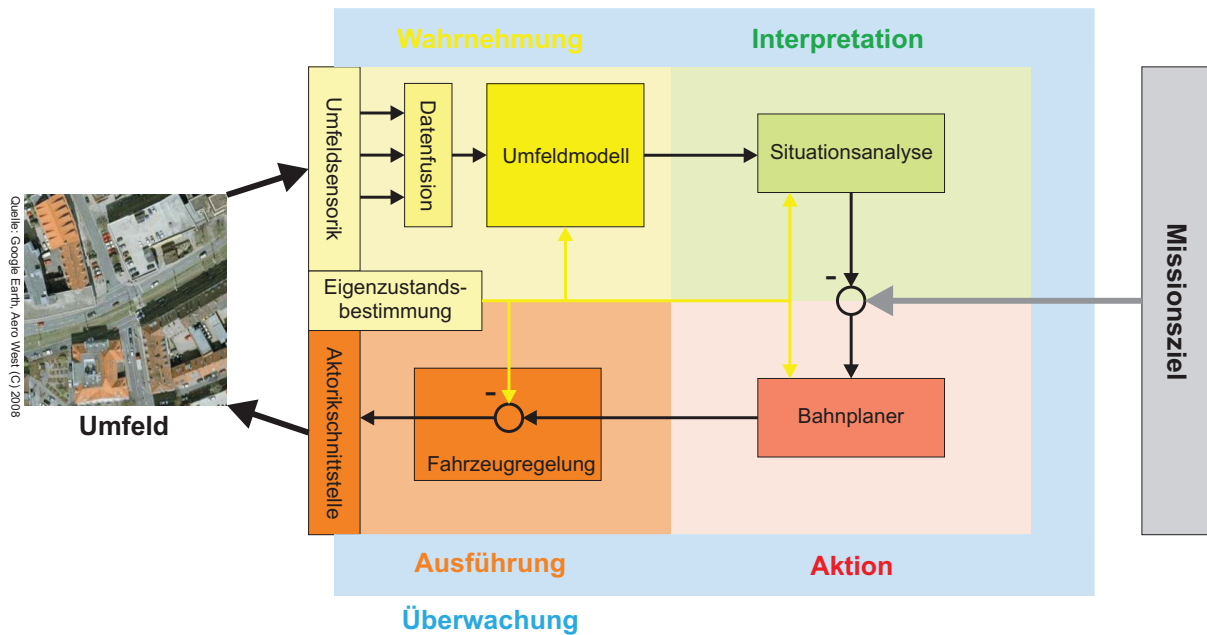


Abb. 4.1: Architekturkonzept für die autonome Fahrzeugführung

Aufbauend auf dem Umfeldmodell erfolgt in der Interpretationsebene die Situationsanalyse und -bewertung. Die Situation wird mit den Missionszielen abgeglichen und im Rahmen der Aktionsebene in eine Solltrajektorie gewandelt. Diese wird in der Ausführungsebene genutzt, um die korrekten Aktorik-Stellgrößen zu berechnen. Es ergibt sich eine kaskadierte Regelkreisstruktur. Der äußere Regelkreis schließt sich über das Fahrzeugumfeld und die extern bereitgestellten Missionsziele, der innere Regelkreis über die Position des Fahrzeugs in der Welt und die vorgegebene Sollbahn. Eine zentrale Rolle nimmt die Erfassung des Fahrzeugzustands ein. Dieser wird im Rahmen der Datenakquisition ermittelt und steht allen Architekturebenen gleichermaßen zur Verfügung.

Im Falle eines vollständig autonomen Systems ist zudem die Einführung einer Überwachungsebene notwendig. Im Fehlerfall ist es ihre Aufgabe, die fehlende menschliche Aufsicht zu ersetzen, Fehlerzustände selbstständig zu beseitigen und das Fahrzeug im Notfall in einen sicheren Betriebszustand zu überführen.

Die im Rahmen dieser Arbeit umgesetzte Fahrzeugarchitektur orientiert sich an der in Abb. 4.1 dargestellten Struktur. Für ein besseres Verständnis des Gesamtsystems wird in den folgenden Abschnitten ein Überblick über das Fahrzeug sowie die beteiligten Funktionsebenen und deren Verknüpfung gegeben. Eine ausführliche Darstellung der Gesamtarchitektur findet sich in Anhang B. Die Module zur maschinellen Umfeldwahrnehmung werden in den Kapiteln 6 und 7 eingehend erläutert.

4.1 Versuchsträger und Hardwarekomponenten

Als Fahrzeugplattform kommt ein Serienkraftfahrzeug vom Typ Volkswagen Passat Variant zum Einsatz, welches werkseitig bereits einen Großteil der notwendigen Aktoren und Aktorikschnittstellen zur Verfügung stellt. Der Versuchsträger ist in Abb. 4.2 dargestellt. Insbesondere die serienmäßig verbaute elektrische Lenkung erweist sich in der Praxis als



Abb. 4.2: Versuchsträger Caroline für die Urban Challenge 2007

Vorteil gegenüber nachgerüsteten Lösungen mit proprietären Lenkmaschinen. Da für die Auswahl der zusätzlich notwendigen Komponenten neben rein funktionalen Aspekten auch der Langzeit-Einsatz im Automobil unter Berücksichtigung der begrenzten Energie-, Kühlungs- und Raumkapazitäten im Vordergrund steht, wird auf Bauteile aus dem Bereich Automobil- und Industrietechnik zurückgegriffen.

4.1.1 Umfelderfassende Sensorik

Der Erfassung von Hindernissen und Wahrnehmung des Fahrbahnverlaufes dienen eine Reihe verschiedenartiger Sensorsysteme:

- An Fahrzeugfront und -heck befinden sich insgesamt drei Mehrebenen-Laserscanner (Abb. 4.3a). Der theoretisch erreichbare Öffnungswinkel der Sensorik wird durch den Verbau am Fahrzeugträger beschränkt, so dass der in Abb. 4.3b dargestellte Beobachtungsbereich resultiert. Aufgrund der Herkunft aus dem automobilen Umfeld weisen die Sensoren eine interne, objektbasierte Datenvorverarbeitung [50] auf und stellen die resultierenden Objektlisten per CAN-Bus zur Verfügung.

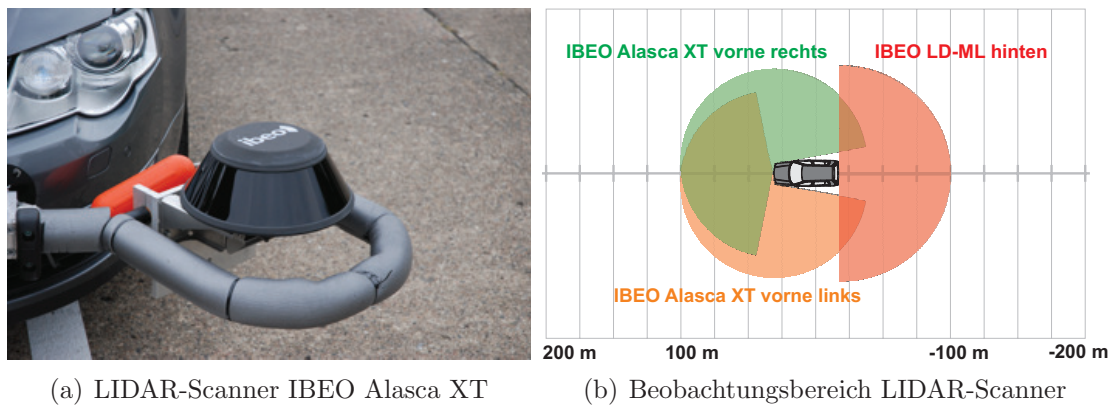


Abb. 4.3: Übersicht LIDAR-Scanner

- Für eine Steigerung der Reichweite und Erhöhung der Redundanz im vorderen und hinteren Fahrzeugbereich werden die LIDAR-Scanner ergänzt durch zwei mehrstrahlige LIDAR-Sensoren (vgl. Abb. 4.4a). Diese erreichen bei einem vergleichsweise geringen Öffnungswinkel von 12 Grad eine Reichweite von ca. 200 Metern und sind ebenfalls mit einer internen Objektvorverarbeitung ausgestattet. Es ergibt sich der in Abb. 4.4b dargestellte Beobachtungsbereich.




Abb. 4.4: Übersicht Mehrstrahl-LIDAR

- Als Ergänzung zur LIDAR-Sensorik kommen insgesamt vier 24 GHz Nah- und Mittelbereichs-Radarsensoren zum Einsatz (vgl. Abb. 4.5a). Diese decken den toten Winkel der LIDAR-Systeme ab und erhöhen durch das alternative Messprinzip die Redundanz des Gesamtsystems. Aufgrund unterschiedlicher Antennencharakteristiken erreichen die Sensoren im vorderen und hinteren Fahrzeugbereich einen Öffnungswinkel von ca. 40 Grad und eine Reichweite von ca. 150 Metern bzw. einen Öffnungswinkel von ca. 140 Grad und eine Reichweite von 15-20 Metern für die Abdeckung des toten Winkels, wie in Abb. 4.5b dargestellt ist. Analog zu den vorangegangenen Sensortypen

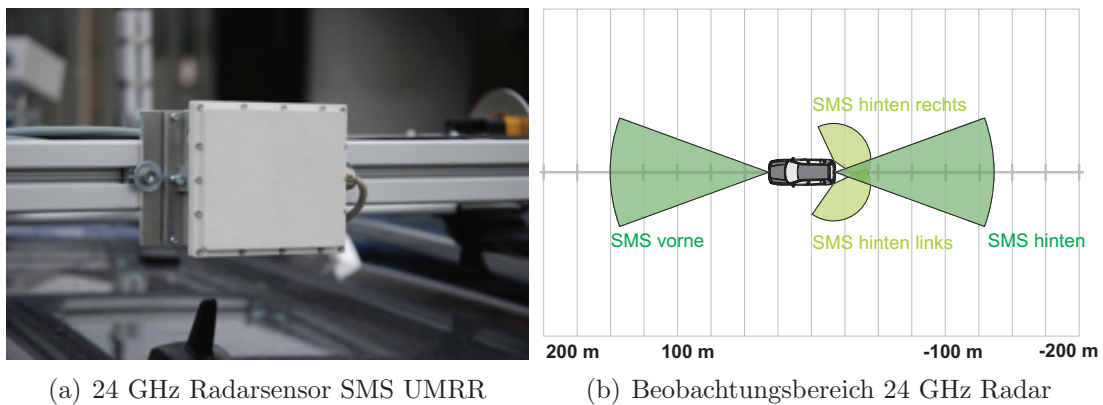


Abb. 4.5: Übersicht Radarsensorik

erfolgt auch hier zunächst sensorintern eine Objektbildung und die Sensoranbindung via CAN-Bus.

Während die objektgebenden Sensoren für die Erfassung von Hindernissen gut geeignet sind, lässt sich über den Verlauf stationärer Randobjekte nur eingeschränkt auf den Verlauf der Fahrbahn schließen. Um diese Anforderungen an die maschinelle Umfeldwahrnehmung zu erfüllen, kommen zwei weitere Sensortypen zum Einsatz:

- Eine Mono-Farbkamera (vgl. Abb. 4.6a) wird eingesetzt, um auf Basis einer Farbsegmentierung des Untergrundes auf den Verlauf der Fahrbahn zu schließen (siehe Abschnitt 7.4). Durch die Wahl des Objektivs ergibt sich ein Öffnungswinkel von ca. 70 Grad bei einer Kamera-Auflösung von 640×480 Pixeln (Abb. 4.6b).

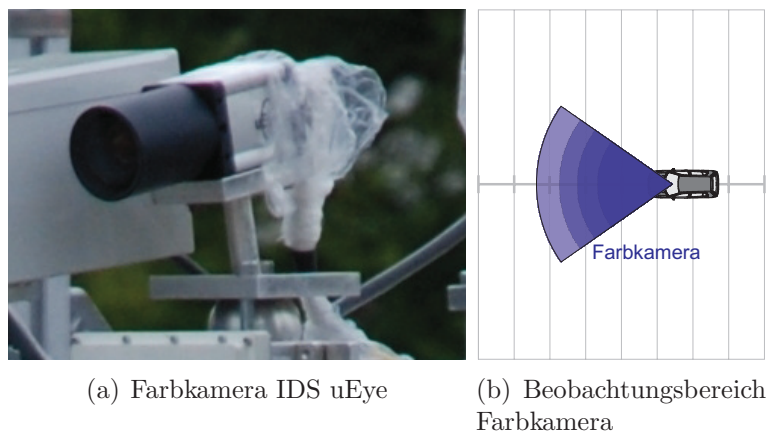


Abb. 4.6: Kamerasystem zur Farbanalyse

- Zwei industrielle Laserscanner (vgl. Abb. 4.7a) kommen zusätzlich zum Einsatz, um das vertikale Profil der Fahrbahnoberfläche abzutasten (vgl. Abschnitt 7.3). Die Sensoren

sind so ausgerichtet, dass die durch den rotierenden Laser aufgespannten Ebenen die Fahrbahnoberfläche bei flachem Untergrund in 10 und 20 Metern vor dem Fahrzeug berühren (vgl. Abb. 4.7b). Bedingt durch den Einbauort am Dachträger des Fahrzeugs ist der Öffnungswinkel der Sensoren auf ca. 120 Grad reduziert.




Abb. 4.7: Laserscanner zur Erfassung der Fahrbahnoberfläche

Darüber hinaus wurde im Rahmen des Projektverlaufs ein Mehrkamerasystem zur Erfassung und modellbasierten Verfolgung von farbigen Fahrspurmarkierungen erprobt [79]. Diese standen im finalen Wettbewerb jedoch nur eingeschränkt zur Verfügung und befanden sich teilweise in Konflikt mit dem gegebenen Kartenmaterial, so dass trotz akzeptabler System-Performance auf den Einsatz verzichtet wurde.

4.1.2 Ortungssystem

Für die Akquisition des Fahrzeugzustands wird das in Abb. 4.8 dargestellte kommerzielle Koppelnavigationssystem bestehend aus Differential GPS Empfänger, Trägheitsplattform und optionaler Radimpulsauswertung verwendet. Durch Nutzung des satellitenbasierten Omnistar-Korrekturdatendienstes [100] lässt sich eine hohe Güte der Absolut-Positionierung erzielen. Ohne die Verwendung einer zusätzlichen lokalen Referenzstation wird unter günstigen Bedingungen eine Genauigkeit im Zentimeterbereich erreicht. Die Auswertung der Trägheitsplattform ermöglicht zudem eine Bestimmung der Fahrzeugorientierung in hoher Güte. Im Rahmen der Datenakquisition werden diese Messdaten um den Lenkwinkel sowie die Lenkwinkelgeschwindigkeit ergänzt, welche auf dem fahrzeugeigenen CAN-Bus zur Verfügung stehen. Der Eigenzustand der Fahrzeugplattform setzt sich somit wie folgt zusammen:

- Fahrzeugposition (x, y, z) ,




Abb. 4.8: Ortungssystem und GPS-Empfangsantenne

- Fahrzeuggeschwindigkeit (v_x, v_y, v_z) ,
- Fahrzeugbeschleunigung (a_x, a_y, a_z) ,
- Fahrzeug-Gierwinkel Ψ und Gierrate $\dot{\Psi}$,
- Fahrzeug-Nickwinkel Θ und Nickrate $\dot{\Theta}$,
- Fahrzeug-Rollwinkel Φ und Rollrate $\dot{\Phi}$,
- Zeitstempel der aktuellen GPS-Zeit t sowie
- Fahrzeug-Lenkwinkel δ und Lenkwinkelgeschwindigkeit $\dot{\delta}$.

Die Angaben werden bezogen auf das in Anhang A.2 definierte Weltkoordinatensystem ausgedrückt. Zu den Messgrößen können überdies die Schätzunsicherheiten der im Navigationssystem integrierten Ortungsfusion abgefragt werden.

4.1.3 Rechnersystem und Fahrzeugintegration

Für die Ausführung der diversen Softwaremodule wird ein verteiltes Rechnercluster verwendet. Hierzu stehen sechs identische Rechnersysteme (siehe (1) in Abb. 4.9) auf Basis eines 2 GHz Intel Pentium Mobile Chipsatzes zur Verfügung, die in speziell automobiltauglichen und passiv gekühlten Gehäusen verbaut und mit stoßresistenten Festplattenlaufwerken ausgerüstet worden sind. Die rechenintensive Bildvorverarbeitung (vgl. Kapitel 7.4.1) wird auf einem zusätzlichen Industrierechner mit Mehrprozessorkern ausgeführt (2). Die Einheiten sind im Kofferraum des Versuchsträgers integriert und über ein 100 Megabit Ethernet Interface verbunden. Die Energieversorgung aller Komponenten wird zudem über elektronisch

ansteuerbare Verteilerboxen (3) geführt. Eine Kommunikation zwischen einzelnen Prozessen und/oder verschiedenen Rechnern wird über eine transparente, speziell entwickelte Middleware realisiert. Diese netzwerkbasierte Architektur ermöglicht eine beliebige Verteilung der




Abb. 4.9: Rechnersystem im Kofferraum des Versuchsträgers

Softwarekomponenten auf die Rechneinheiten, wodurch sich gleichmäßige Auslastung, effiziente Nutzung der Hardware-Ressourcen sowie eine hohe Skalierbarkeit erreichen lassen. In der untersten Softwareebene setzen spezielle Akquisitions- und Ansteuerungsmodule die heterogenen Schnittstellen zu den Sensor-Steuergeräten (4) und Aktorikkomponenten (5) auf die einheitliche Ethernet-basierte Kommunikation um. Im Rahmen der vier übergeordneten Funktionsebenen ist somit keine Berücksichtigung der physikalischen Datenanbindung notwendig. Im Zuge des Umsetzungsvorgangs erfolgt eine Transformation aller Messdaten auf das in Abschnitt A.2 definierte Weltkoordinatensystem. Alle Messdaten werden somit in Bezug auf eine einheitliche Koordinatendarstellung ausgedrückt, wodurch aufwendige und fehleranfällige Zwischentransformationen zwischen den Softwaremodulen vermieden werden. Die für die Transformation erforderliche Messgüte des Fahrzeug-Eigenzustandes wird durch die Ortungsplattform sichergestellt.

Zur Synchronisation der Rechner wird der von der Ortungsplattform ermittelte Zeitstempel als Master-Zeit per Network Time Protocol [90] bereitgestellt. Es lässt sich dadurch ohne größeren Implementierungsaufwand eine Synchronität im Bereich weniger Mikrosekunden erreichen.

4.2 Wahrnehmungsebene und hybrides Umfeldmodell

Es ist die Aufgabe der Wahrnehmungsebene, die überlagerte Funktion von den individuellen Sensorsystemen zu entkoppeln und ein für verschiedene Teilfunktionen allgemeingültiges Umfeldmodell zur Verfügung zu stellen [27]. An dieser Stelle lässt sich die Beschränkung

aktueller Fahrerassistenzsysteme auf den außerstädtischen Bereich maßgeblich auf die unzureichende Leistungsfähigkeit der für die Umfeldwahrnehmung verwendeten, simplen Objektmodelle zurückführen. Es ist offensichtlich, dass eine Reduktion des Fahrzeugumfeldes auf z.B. quaderförmige Fahrzeugmodelle [66, 67, 34] oder simple Fahrspurverläufe [56, 73, 86, 97] etc.) an ihre Grenzen stößt, wenn die tatsächlichen Umfeldmerkmale nicht oder nicht hinreichend mit der Modellvorgabe übereinstimmen. Für eine autonome Fahrzeugführung in urbaner Umgebung gilt diese Problematik in besonderem Maße, da neben der Beschreibung von Fremdfahrzeugen auch eine zuverlässige Abbildung von Bestandteilen der Infrastruktur im Fahrbahn-Randbereich erforderlich ist (vgl. Abb. 4.10a bis 4.10c). Diese entziehen sich einer simplen Modellvorgabe, so dass vor allem eine Flexibilisierung des Objektmodells erforderlich ist.

Analoges gilt für die Modellierung des Fahrbahnverlaufs. Aufgrund der engen Kurvenradien, komplexer Strukturen im Kreuzungsbereich sowie unter Umständen völlig frei gestalteter Parkflächen gilt es, eine modellfreie Repräsentation des überfahrbaren Bereiches zu entwickeln. Hierbei kommt erschwerend hinzu, dass innerhalb weniger hundert Meter Fahrtstrecke unterschiedlichste Merkmale wie Bordsteinkanten, Böschungen, Spurmarkierungen oder der Farbunterschied zum Grünstreifen die relevanten Merkmalsträger für eine Abgrenzung der Fahrbahn sind. Um eine für die autonome Fahrzeugführung geeignete Umfeldwahrnehmung




Abb. 4.10: Urbanes Umfeld im Urban Challenge Wettbewerb

zu entwickeln, wird die Kombination objekt- und kartenbasierter Umfeldmodelle angestrebt [39, 37, 40]. Für die Hinderniserkennung gilt es, die Fähigkeiten der objektbasierten Zustandsschätzung zur Beschreibung dynamischer Vorgänge im Fahrzeugumfeld mit dem kartenbasierten Ansatz zur Beschreibung beliebig komplexer Strukturen zu koppeln. Für die Fahrbahnmodellierung gilt es, unter Missachtung vorhandener dynamischer Objekte eine kartenbasierte Repräsentation der statischen Befahrbarkeit zu entwickeln.

Die Messdaten der in Abschnitt 4.1.1 vorgestellten Sensorsysteme werden hierzu in ein hybrides Umfeldmodell überführt, dessen Signalfluss Abb. 4.11 zeigt. Eine detaillierte Erörterung der objekt- und kartenbasierten Wahrnehmungsmodule erfolgt in den Kapiteln 6

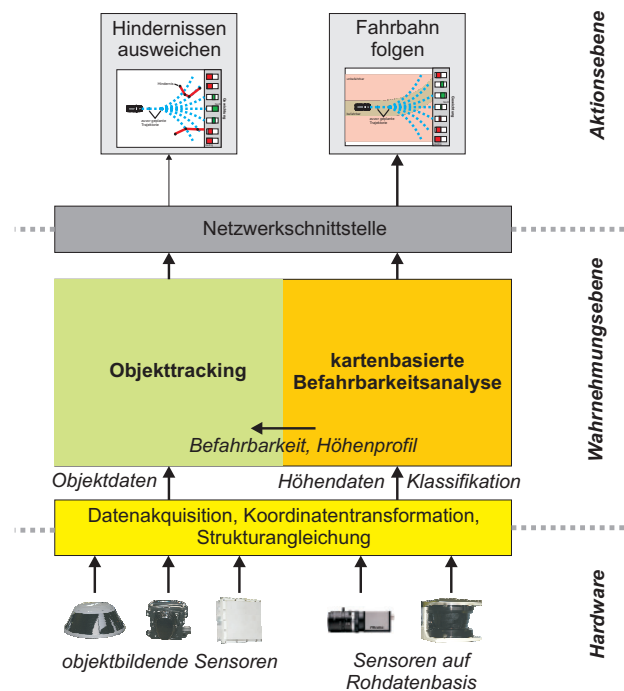


Abb. 4.11: Architektur der Fahrzeug-Umfelderfassung

und 7. Die Ausgangsdaten der hybriden Darstellung werden der im nächsten Abschnitt erläuterten Bahnplanung zugeführt. Gemeinsam mit den ebenfalls verfügbaren Missionsdaten (Wegpunktliste und Straßennetzwerk) bilden diese die Basis für eine regelkonforme und kollisionsfreie Längs- und Querführung. Sowohl die objekt- als auch die kartenbasierte Umfeldmodellierung lassen sich auf das Prinzip der Bayes'schen Informationsverarbeitung zurückführen, auf das im nächsten Kapitel näher eingegangen werden soll.

4.3 Interpretations- und Aktionsebene / Bahnplanung

Für die Fahrzeugführung wird auf ein verhaltensbasiertes [106] Fahrentscheider-Konzept zurückgegriffen. Zur Generierung der Sollbahn wird die in Kapitel 3.2 skizzierte Potentialfeldmethode verwendet. Um die Behandlung von Spezialsituationen zu ermöglichen, wird die Bahnplanung weiterhin um eine Reihe von Zustandsautomaten erweitert.

4.3.1 Grundlegende Fahrzeugführung nach DAMN

Alle grundlegenden Fahrentscheidungen des Versuchsträgers werden auf Basis des in [107] vorgestellten DAMN-Verfahrens (Distributed Architecture for Mobile Navigation) getroffen. Die Planung erfolgt inkrementell (einmalig) von der aktuellen Fahrzeugposition aus und setzt anschließend auf den zuvor geplanten Teilsegmenten auf. In jedem Planungsschritt wird eine feste Anzahl möglicher Folgetrajektorien erzeugt. Diese werden durch Kreisbögen variabler Krümmung dargestellt (vgl. Abb. 4.12a). Die möglichen Folgetrajektorien werden anschlie-

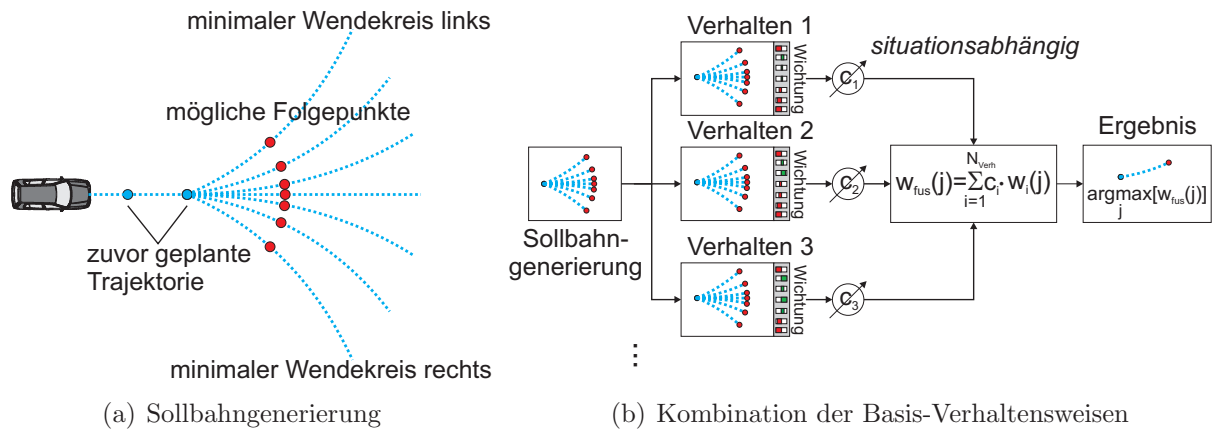


Abb. 4.12: DAMN-Konzept zur Fahrzeugführung

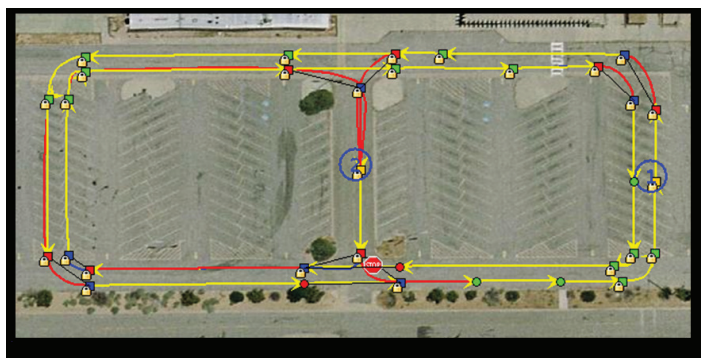
ßend bezüglich einer Reihe elementarer Verhaltensweisen gewichtet. Diese Verhaltensweisen beschreiben die Reaktion des Fahrzeugs auf Elemente des Umfeldmodells sowie die Navigationsdaten. Für jede Basis-Verhaltensweise erfolgt zunächst eine Bewertung aller möglichen Folgetrajektorien, anschließend werden die Gewichte über alle Verhaltensweisen hinweg kombiniert (vgl. Abb. 4.12b). Die Kombination besteht aus der Addition der Teilgewichte, wobei die Komponenten situationsabhängig unterschiedlich stark mit einfließen [105].

Für die Querführung sollen im Folgenden die wichtigsten Basis-Verhaltensweisen skizziert werden, die Längsführung (Wahl der Eigengeschwindigkeit) erfolgt nach dem identischen Muster.


Wegpunkt-Folgeverhalten

Die im Wettbewerb vorgegebenen Missionsdaten setzten sich zusammen aus einem Wegpunkt-Graphen sowie einer Liste darin enthaltener, abzufahrender Checkpunkte (vgl. Abb. 4.13a). Mit Hilfe dieser Missionsziele sowie der bekannten Fahrzeug-Eigenposition kann die Liste der sequentiell abzufahrenden Folgewegpunkte bestimmt werden. Eine zeitlich optimierte Planung lässt sich durch Speicherung der Fahrzeit zwischen den Wegpunkten im Graphen erreichen, so dass bei mehrmaligem Durchfahren ungünstige Streckenabschnitte nach Möglichkeit gemieden werden.

Die Wichtung der möglichen Folgetrajektorien erfolgt in zwei Schritten. Zunächst wird die optimale Krümmung berechnet, welche direkt auf den gewünschten Wegpunkt hinführt (rot in Abb. 4.13b). Anschließend wird die Wichtung über die Krümmungsdifferenz der einzelnen Kreisbögen zur optimalen Krümmung vorgenommen. Derjenige Kreisbogen, welcher der optimalen Krümmung am ähnlichsten ist, erhält das größte Gewicht.



(a) Wegpunkt-Graph



(b) Folgeverhalten

Abb. 4.13: Kartenmaterial und Wegpunkt-Folgeverhalten

Ausweichverhalten

Die zweite grundlegende Verhaltensweise des Fahrzeugs besteht darin, Hindernissen in jedem Fall auszuweichen. Das in Kapitel 6 erläuterte Objekttracking überführt die Daten der umfelderfassenden Sensorsysteme hierzu in eine gemeinsame Darstellung, bei der die Kontur jedes Hindernisses durch einen freien Polygonzug beschrieben wird. Die möglichen Folgetrajektorien des DAMN-Ansatzes werden um die Fahrzeugbreite ausgedehnt und die resultierenden Fahrschläuche auf darin enthaltene Hindernisse überprüft (vgl. Abb. 4.14b). Liegen eines oder mehrere Hindernispolygone im Fahrschlauch, so wird dieser durch Nullsetzen des Gewichtes verboten.

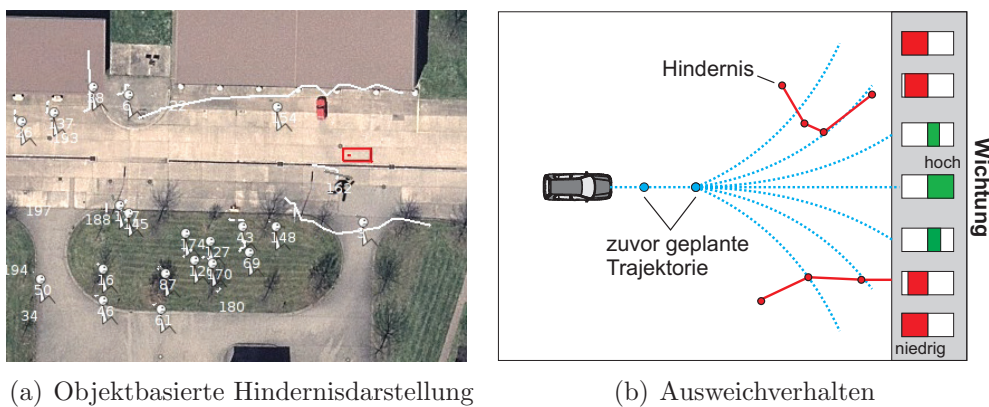


Abb. 4.14: Hindernisdarstellung und Ausweichverhalten

Fahrbahn-Folgeverhalten

Insbesondere im Bereich von Kurven ist eine Interpolation zwischen den Wegpunkten für die sichere Fahrzeug-Querführung nicht ausreichend. Allerdings kann auch nicht davon ausgegangen werden, dass der Straßenverlauf stets durch sichtbare Hindernisse begrenzt wird. Aus diesem Grund wird im dritten Basis-Verhalten die Befahrbarkeit des Untergrundes in Betracht gezogen, um ein Abkommen von der Fahrbahn zu verhindern.

Als Eingangsdaten dient das in Kapitel 7 näher beschriebene probabilistische Befahrbarkeitsmodell, welches das Umfeld in befahrbare, unbefahrbare und unbekannte Abschnitte einteilt (Abb. 4.15a). Die Wichtung der möglichen Folgetrajektorien des DAMN-Ansatzes erfolgt entsprechend der Befahrbarkeit des Untergrundes (Abb. 4.15b), sodass Gebiete mit hoher Befahrbarkeit bevorzugt werden.

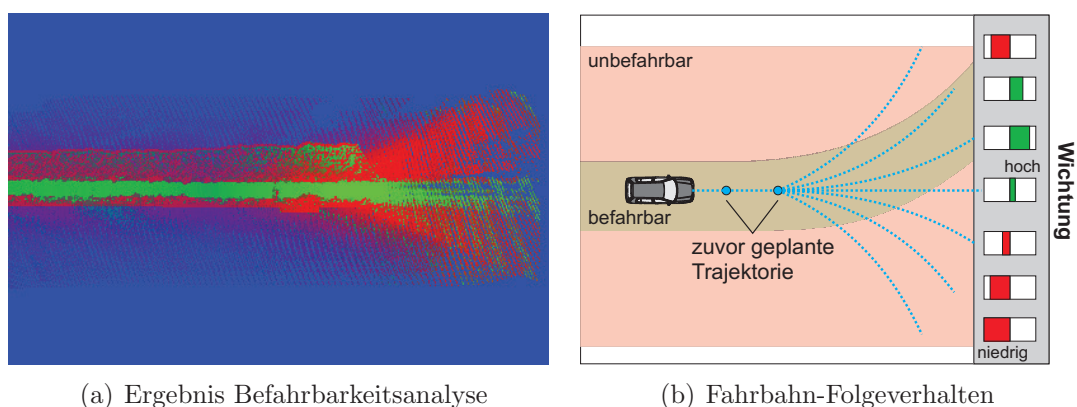


Abb. 4.15: Befahrbarkeitsdarstellung und Folgeverhalten

4.3.2 Zustandsbasierte Erweiterung der Fahrzeugführung

Gemäß der zuvor skizzierten Führungsstrategie ist das Fahrzeug stets in Bewegung und dabei bemüht, das Optimum aus der Kombination der drei Basisverhalten einzunehmen. Es ist offensichtlich, dass auf diese Weise nur ein Teilbereich der Fahraufgaben bewältigt werden kann. Die drei Basisverhalten sind hierbei vergleichbar mit dem Automatismus eines menschlichen Fahrers, der unterbewusst einen Großteil der Quer- und Längsführungsaufgaben verrichtet.

Kommt es jedoch zur Interaktion mit anderen Verkehrsteilnehmern oder einer notwendigen Berücksichtigung von Verkehrsregeln, ist eine bewusste und vor allem deterministische Entscheidungsfindung notwendig. Situationen dieser Art stellen somit eine Ausnahme vom normalen Fahrbetrieb dar und müssen gesondert behandelt werden.

Um diesen Anforderungen gerecht zu werden, lässt sich die verhaltensbasierte Fahrzeugführung durch spezialisierte Zustandsmaschinen im Rahmen von Unterbrechungsroutinen (Interrupts) erweitern, wie in Abb. 4.16 dargestellt ist. Im Rahmen der Situationsanalyse

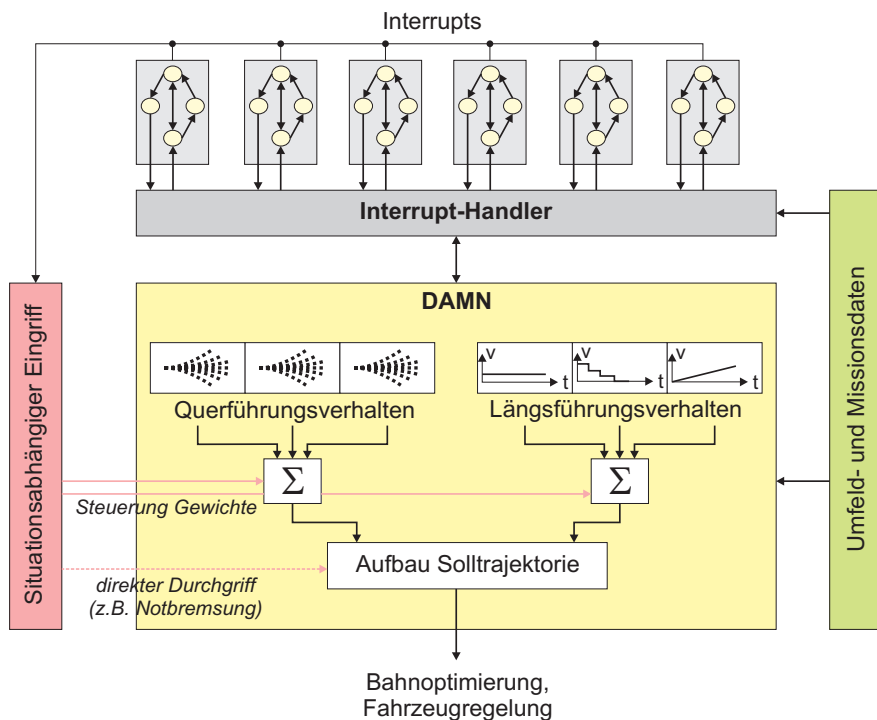


Abb. 4.16: Kombination verhaltens- und ereignisgesteuerte Fahrzeugführung

wird zyklisch überprüft, ob die Bedingungen für die Aktivierung einer Interrupt-Routine eingetreten sind (Interrupt-Handler). Ist dies der Fall, wird eine spezialisierte Zustandsmaschine aktiviert. Diese kann die Kontrolle über das Fahrzeug komplett übernehmen (direkter

Durchgriff) oder alternativ auf die Wichtung der Basis-Verhaltensweisen Einfluss nehmen. Situationsabhängig lassen sich so verschiedene Verhaltensweisen aktivieren oder deaktivieren.

Am Beispiel des Fahrzeug-Verhaltens in Kreuzungssituationen soll dieses Vorgehen erläutert werden.

- Im Rahmen des Interrupt-Handlers wird während der Fahrt laufend überprüft, ob das Fahrzeug in den Einzugsbereich einer Kreuzung eintritt. Ist diese Bedingung erfüllt, so geht die Kontrolle an den Kreuzungs-Interrupt über.
- Zu Beginn des Kreuzungsinterrupts wird eine Stopptrajektorie gesendet, d.h. die Fahrgeschwindigkeit wird in den geplanten Teiltrajektorien schrittweise auf Null reduziert. Dies führt zu einem definierten Anhalten des Fahrzeugs an der Haltelinie der Kreuzung.
- Wurde die Stopplinie erreicht, so wird die aktuelle Vorfahrtsituation an der Kreuzung evaluiert. Zunächst wird der interessante Bereich im Umfeld durch sog. Suchpolygone (Abb. 4.17b) eingegrenzt. Diese Suchbereiche werden anschließend auf das Vorhandensein statischer oder dynamischer Hindernisse überprüft.

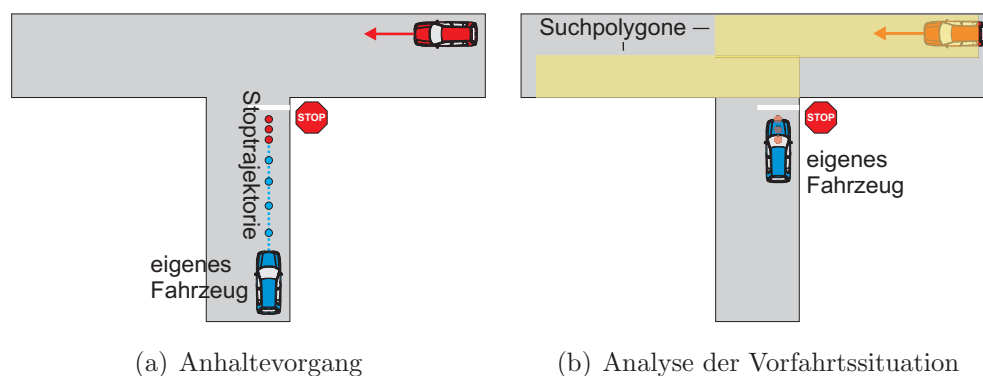


Abb. 4.17: Kreuzungsverhalten durch Ereignissteuerung

- Die Prüfung wird so lange fortgeführt, bis alle relevanten Suchbereiche frei von Hindernissen sind und eine sichere Weiterfahrt vorausgesetzt werden kann. Ist dies der Fall, wird der Kreuzungsinterrupt beendet.
- Im Rahmen der Interrupt-Beendigung wird der korrekte Folgewegpunkt (Austrittspunkt aus der Kreuzung) bestimmt und die verhaltensbasierte Bahnplanung in den Normalbetrieb zurückversetzt.

Für jede Spezialsituation wird eine spezialisierte Zustandsmaschine entworfen und in die verhaltensbasierte Fahrzeugführung integriert. Auf Basis dieses modularen Funktionszuwachses

können Überholvorgänge, Parkaufgaben, Notbremsungen, Wendemanöver sowie alle Arten von Vorfahrtsituationen unabhängig voneinander entworfen und getestet werden.

4.3.3 Dynamische Bahnoptimierung

Es zeigt sich als besondere Herausforderung der Bahnplanung, dass die generierten Trajektorien nicht nur funktionalen Aspekten, sondern auch den physikalischen Randbedingungen der Fahrdynamik genügen müssen. Hierbei sind insbesondere Sprünge in der Krümmung der Sollbahn zu vermeiden, da diese vom Fahrzeug nur durch eine unendlich große Lenkwinkelgeschwindigkeit abgebildet werden können [128]. Leider zeichnet sich gerade das gewählte Prinzip zur Bahnplanung über die Aneinanderreihung von Kreisbogensegmenten durch eine Vielzahl von Krümmungsunstetigkeiten aus, sodass eine nachträgliche Bahnoptimierung erfolgen muss. Die geplanten Kreisbogensegmente werden dazu in eine Liste von Stützstellen \mathbf{p}_i mit definiertem Abstand überführt. Zwischen den Stützstellen erfolgt die Interpolation in der Art, dass eine glatte, krümmungsstetige Sollbahn erzeugt wird. Zur Interpolation kommt ein kubischer B-Spline [102] zum Einsatz. Sei \mathbf{p}_i die aktuell angefahrte Stützstelle, so ergibt sich die interpolierte Sollbahn zu:

$$\mathbf{p}(t) = \begin{bmatrix} t^3 & t^2 & t & 1 \end{bmatrix} \frac{1}{6} \begin{bmatrix} -1 & 3 & -3 & 1 \\ 3 & -6 & 3 & 0 \\ -3 & 0 & 3 & 0 \\ 1 & 4 & 1 & 0 \end{bmatrix} \begin{bmatrix} \mathbf{p}_{i-1} \\ \mathbf{p}_i \\ \mathbf{p}_{i+1} \\ \mathbf{p}_{i+2} \end{bmatrix} \quad \forall t \in [0, 1] \quad (4.1)$$

Die Stetigkeit in Bezug auf Position und Krümmung lässt sich aufrechterhalten, wenn während des Fahrvorgangs zwischen \mathbf{p}_i und \mathbf{p}_{i+1} die Stützstellen \mathbf{p}_{i-1} bis \mathbf{p}_{i+2} durch die übergeordnete Bahnplanung nicht verändert werden. Die Sollbahn wird hierzu in einzelne Teilseg-




Abb. 4.18: Spline-Interpolation zur dynamischen Bahnoptimierung

mente aufgeteilt (vgl. Abb. 4.18). Die Bahnplanung hat sicherzustellen, dass die Planung des bereits aktiven Segmentes nur im Ausnahmefall (z.B. drohende Kollision) verändert wird. In Kombination mit der Fahrzeug-Eigenposition lässt sich mit Hilfe von Gleichung (4.1) innerhalb jedes Segmentes eine für die Querregelung benötigte Kurswinkeldifferenz und Querablage des Fahrzeugs errechnen.

4.4 Ausführungsebene

Die Ausführungsebene stellt die Aktorikschnittstellen des Fahrzeugs für die Längs- und Querregelung zur Verfügung. Der von der Fahrzeugregelung errechnete Bremsdruck P_{soll} , die Gaspedalstellung T_{soll} sowie der gewünschte Lenkwinkel δ_l werden per CAN-Bus an die Hardwarekomponenten übermittelt.

4.4.1 Längs- und Querregelung

Die Längsregelung ist als klassische P-PI Kaskadenstruktur ausgelegt (vgl. Abb. 4.19). Da die Dynamik des Brems- und Beschleunigungskreises stark unterschiedlich ist, kommen unabhängige Regler zum Einsatz. Eine vordefinierte Logik am Ausgang der beiden Regelkreise verhindert das unerwünschte gleichzeitige Bremsen und Beschleunigen [127]. Die für den

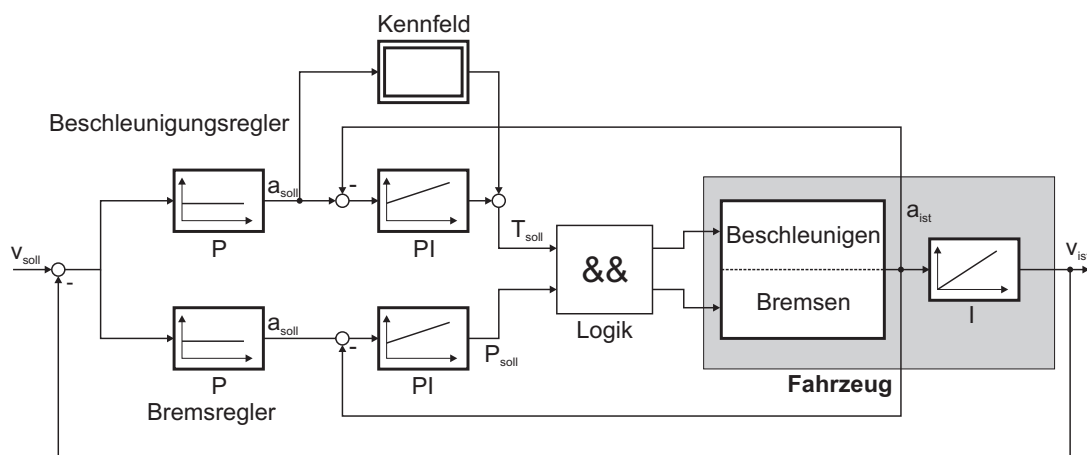


Abb. 4.19: Struktur der Fahrzeug-Längsregelung

inneren Regelkreis benötigte Ist-Beschleunigung des Fahrzeugs steht über die Ortungsplattform (siehe Abschnitt 4.1.2) zur Verfügung. Um das Führungsverhalten des Reglers während

der Beschleunigungsphase zu verbessern, erfolgt weiterhin eine Vorsteuerung der Gaspedalstellung mit Hilfe eines inversen Motorkennfeldes.

Für die Querregelung kommt die in Abb. 4.20 dargestellte parallele Regelkreisstruktur zum Einsatz [127]. Die Stellgröße für den Lenkwinkel δ_l errechnet sich aus drei Komponenten:

- Mit Hilfe der aktuellen Bahnkrümmung κ_{ist} , die der Spline-Darstellung entnommen werden kann, lässt sich der Lenkwinkel für ein störungsfreies Abfahren der Bahn vorsteuern.
- Die Querablage d_{ist} von der Sollbahn wird über einen Proportionalregler zu Null geregelt.
- Die Kurswinkeldifferenz $\Delta\Psi_{ist}$ zwischen der Ausrichtung der Bahn und der Fahrzeugorientierung Ψ_{ist} wird über einen zweiten Proportionalregler rückgeführt.

Die drei Ausgänge werden aufsummiert und an den Lenkaktuator des Fahrzeugs übermittelt. Da die Fahrzeugdynamik abhängig von der momentanen Fahrgeschwindigkeit ist, werden die Verstärkungsfaktoren der Proportionalregler über ein Parameterscheduling geschwindigkeitsabhängig eingestellt. Es wurden dazu für verschiedene Fahrgeschwindigkeiten optimale Parameter identifiziert, zwischen denen eine lineare Interpolation erfolgt.

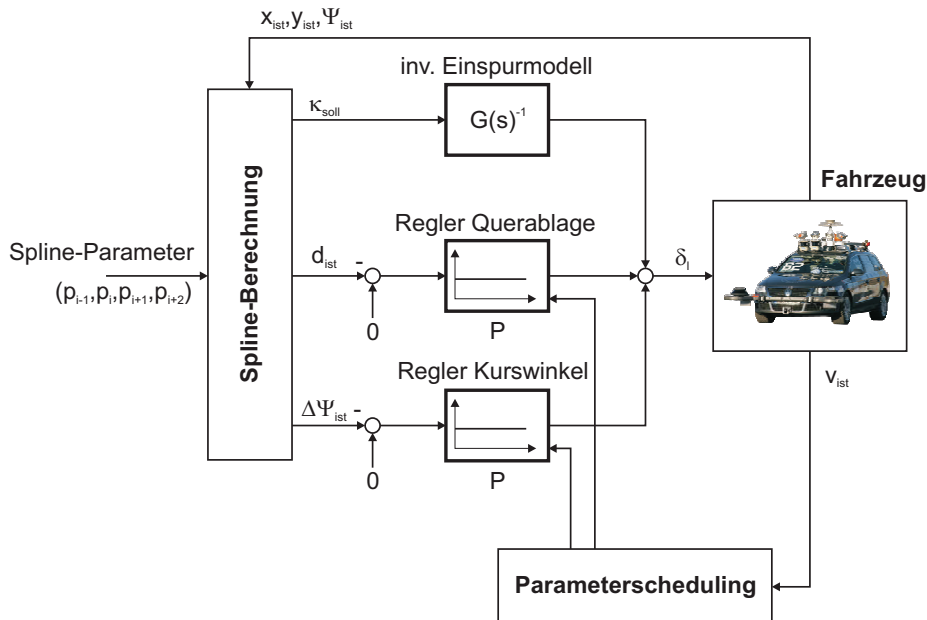


Abb. 4.20: Struktur der Fzg.-Querregelung

4.5 Überwachungsebene

Um die Zuverlässigkeit und Betriebssicherheit des Fahrzeugs zu jedem Zeitpunkt sicherzustellen, ist die Entwicklung einer automatischen Systemüberwachung von zentraler Bedeutung. Im Fehlerfall ist auf dem schnellstmöglichen Wege ein sicherer Betriebszustand anzunehmen. Wegen der fehlenden Möglichkeit eines menschlichen Eingriffs im eigentlichen Wettbewerb ist zudem die Realisierung einer automatischen Fehlerbehebung notwendig. Um diesen Anforderungen gerecht zu werden, wird das in Abb. 4.21 dargestellte zweistufige Überwachungskonzept in die Architektur des Fahrzeugs integriert.

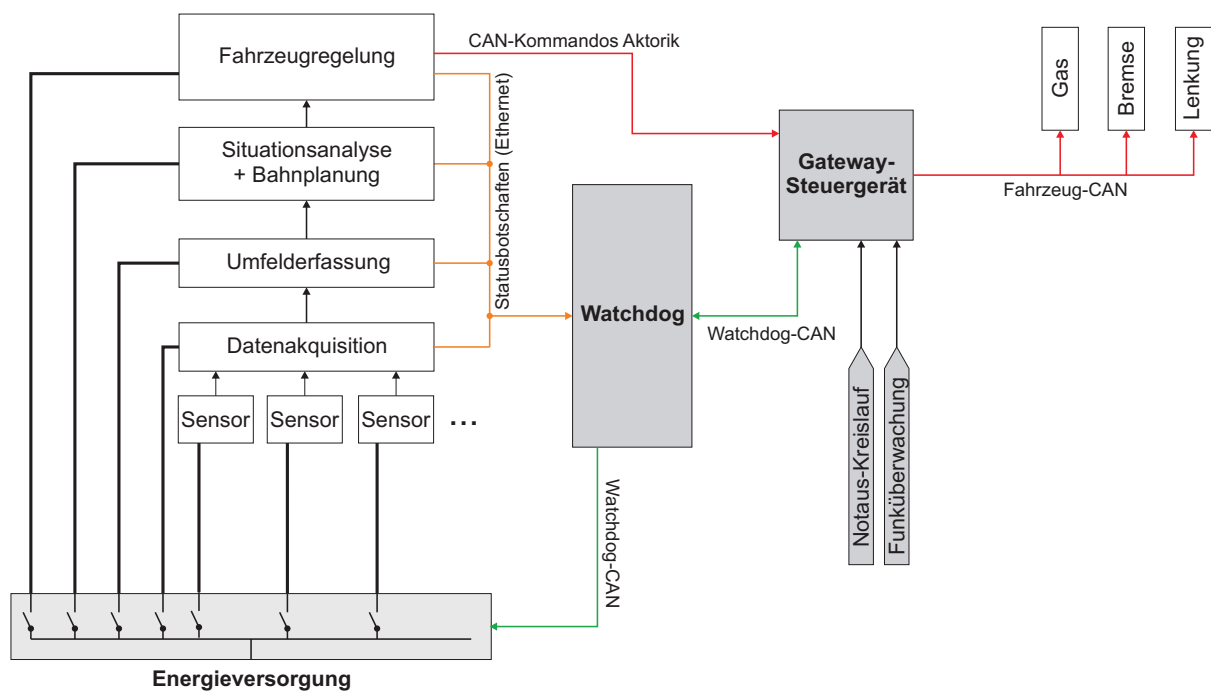


Abb. 4.21: Konzept zur Fahrzeugüberwachung

- Die erste Stufe dient der Kommunikationsüberwachung sowie einer grundlegenden Fehlerbehandlung. Die Aktorik-Befehle des Fahrzeugreglers werden über ein zentrales Gateway-Steuergerät geführt. Im Normalfall werden alle Botschaften direkt an die Aktorikkomponenten des Fahrzeugs weitergeleitet. Im Fehlerfall wird das Durchleiten augenblicklich unterbrochen. Als Fehler wird ein menschlicher Eingriff in Lenkung oder Bremse, die Aktivierung des fahrzeugeigenen Notalarm-Kreises, eine Unterbrechung in der Kommunikation sowie eine Fehlersignalisierung durch die zweite Überwachungsstufe aufgefasst. In Abhängigkeit des konfigurierbaren Betriebsmodus (bemannte Fahrt

oder unbemannter Betrieb) geht die Kontrolle dabei entweder an den menschlichen Sicherheitsfahrer zurück oder es wird eine automatische Notbremsung eingeleitet.

- In der zweiten Stufe erfolgt eine Überwachung der übergeordneten Softwarekomponenten. Diese senden zyklisch Statusbotschaften an ein zentrales Watchdog-Modul. Bleibt eine Statusbotschaft aus oder wird in dieser ein Fehler signalisiert, so kann entsprechend reagiert werden. Im Rahmen einer Fehleranalyse wird zunächst die Schwere des Fehlers bewertet und eine automatische Fehlerbehebung gestartet. Im Falle eines Software-Fehlers wird der betroffene Prozess beendet und neu gestartet. Schlägt diese Wiederherstellung fehl, so kann vom Überwachungsrechner aus die Energieversorgung der betroffenen Komponente ab- und wieder angeschaltet werden. Das Fahrzeug wird während der automatischen Fehlerbehebung in einen sicheren Betriebszustand überführt und kann anschließend den Fahrbetrieb wieder aufnehmen.

5 Theoretische Grundlagen

Im Rahmen dieses Kapitels sollen die theoretischen Grundlagen für die objekt- und kartenbasierte Umfeldmodellierung bzw. die damit verbundenen Algorithmen erarbeitet werden. Beide Ansätze lassen sich auf eine gemeinsame informationstheoretische Basis zurückführen, die auf folgende Überlegungen zurückgeht:

- In einer a priori unbekannten Umgebung werden durch ein Sensorsystem Informationen gesammelt, welche Rückschlüsse auf den Zustand der Umgebung zulassen.
- Der Zusammenhang zwischen Messdaten und Systemzustand ist über ein Sensormodell bekannt. Die Messdaten sind jedoch durch additive Rauschprozesse gestört.
- Es wird vorausgesetzt, dass die Eigendynamik des Umfelds bekannt ist. Auf Basis eines zuletzt bekannten Zustandes kann somit der Folgezustand berechnet werden.
- Sind sowohl Messrauschen als auch Dynamikmodell bekannt, so kann eine zeitliche Integration der Messinformation erfolgen, um den Informationsgehalt über den wahren Zustand der Umgebung kontinuierlich zu steigern. Dieser wird durch einen Schätzwert angenähert. Mit jeder neu eingehenden Messung steigt die Zuverlässigkeit der Schätzung.

In Abbildung 5.1 ist dieser rekursive Prozess graphisch dargestellt. Zu Beginn jedes Schätz-




Abb. 5.1: Rekursiver Filterprozess für die Umfeldwahrnehmung

vorgangs wird der neu eingehende Informationsgehalt (die Innovation) als Differenz zwischen dem tatsächlich eingegangenen Messwert und dem über Dynamik- und Sensormodell berechneten erwarteten Messwert berechnet. Die Innovation wird über eine Korrekturfunktion zur Aktualisierung des Zustandsschätzwertes herangezogen.

Überführt man diese Überlegungen in eine probabilistische Beschreibungsform, so lässt sich der Bayes'sche Filteralgorithmus ableiten.

5.1 Der Bayes'sche Filteralgorithmus

Grundlage der folgenden Betrachtungen ist Bayes Theorem für die Verrechnung von bedingten Wahrscheinlichkeiten [20]. Es gilt

$$P[A|B] = \frac{P[B|A] \cdot P[A]}{P[B]}. \quad (5.1)$$

Die Wahrscheinlichkeit für das Ereignis A unter der Bedingung B lässt sich demnach ausdrücken durch die Wahrscheinlichkeit für das Ereignis B unter der Bedingung A multipliziert mit der Wahrscheinlichkeit des Ereignisses A und dividiert durch die Einzelwahrscheinlichkeit von B .

Für die weitere Herleitung hilfreich ist ferner das Theorem der totalen Wahrscheinlichkeit. Es gelte das Prinzip der Vollständigkeit, d.h.:

$$P[B] = \sum_{i=1}^N P[B|A_i] \cdot P[A_i]. \quad (5.2)$$

Diese abstrakte Definition der Wahrscheinlichkeitstheorie soll für das Prinzip der Umfeldmodellierung konkretisiert werden. Es wird zunächst von diskreten Wahrscheinlichkeiten auf einen kontinuierlichen Zustandsraum übergegangen. Es sei $p(\mathbf{x})$ die Wahrscheinlichkeitsdichtefunktion des kontinuierlichen Zustandsvektors \mathbf{x} . Ziel der Bayes'schen Filterung ist die Bestimmung der Wahrscheinlichkeitsdichte unter Berücksichtigung aller eingehenden Messinformationen (a-posteriori Wahrscheinlichkeit). Auf Basis dieser Verteilung lässt sich jeder beliebige Schätzwert für den wahren Systemzustand ableiten. Gängige Schätzwerte sind hierbei in Abb. 5.2 dargestellt.

Es sei der Vektor \mathbf{y} die Messinformation eines beliebigen Sensorsystems. Man definiert die Gesamtheit aller zur Verfügung stehenden Messvektoren bis zum Zeitpunkt k zu

$$\mathbf{Y}_k = \{\mathbf{y}_0, \dots, \mathbf{y}_k\}. \quad (5.3)$$




Abb. 5.2: Wahrscheinlichkeitsverteilung und mögliche Schätzwerte

Die gesuchte a-posteriori Wahrscheinlichkeitsverteilung des Zustandsvektors \mathbf{x} lässt sich als bedingte Wahrscheinlichkeitsdichte ausdrücken. Diese ergibt sich zu

$$p(\mathbf{x}_{k+1} | \mathbf{Y}_{k+1}) = p(\mathbf{x}_{k+1} | \mathbf{y}_{k+1}, \mathbf{Y}_k). \quad (5.4)$$

Die Bedingung über alle Messungen \mathbf{Y}_{k+1} wurde hierbei aufgeteilt in die Bedingung durch den neu eingehenden Messvektor \mathbf{y}_{k+1} und den Satz aller zurückliegenden Messwerte \mathbf{Y}_k . Die Anwendung von Bayes Theorem aus Gleichung (5.1) führt zu

$$p(\mathbf{x}_{k+1} | \mathbf{y}_{k+1}, \mathbf{Y}_k) = \frac{p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}, \mathbf{Y}_k) \cdot p(\mathbf{x}_{k+1} | \mathbf{Y}_k)}{p(\mathbf{y}_{k+1} | \mathbf{Y}_k)}. \quad (5.5)$$

Mit Hilfe des Gesetzes der totalen Wahrscheinlichkeit aus Gleichung (5.2) lassen sich einige Terme umstellen. Es gilt

$$p(\mathbf{x}_{k+1} | \mathbf{Y}_k) = \int p(\mathbf{x}_{k+1} | \mathbf{x}_k, \mathbf{Y}_k) \cdot p(\mathbf{x}_k | \mathbf{Y}_k) d\mathbf{x}_k \quad \text{und} \quad (5.6)$$

$$p(\mathbf{y}_{k+1} | \mathbf{Y}_k) = \int p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}, \mathbf{Y}_k) \cdot p(\mathbf{x}_{k+1} | \mathbf{Y}_k) d\mathbf{x}_{k+1}. \quad (5.7)$$

Man erhält die Urform des Bayes'schen Filteralgorithmus zu:

$$p(\mathbf{x}_{k+1} | \mathbf{y}_{k+1}, \mathbf{Y}_k) = \frac{p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}, \mathbf{Y}_k) \cdot \int p(\mathbf{x}_{k+1} | \mathbf{x}_k, \mathbf{Y}_k) p(\mathbf{x}_k | \mathbf{Y}_k) d\mathbf{x}_k}{\int p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}, \mathbf{Y}_k) \cdot \int p(\mathbf{x}_{k+1} | \mathbf{x}_k, \mathbf{Y}_k) p(\mathbf{x}_k | \mathbf{Y}_k) d\mathbf{x}_k d\mathbf{x}_{k+1}}. \quad (5.8)$$

Diese Beziehungen können durch die Voraussetzung einiger Annahmen an die Natur des Umfeldmodells vereinfacht werden:

- Es wird angenommen, dass ein Markov-Prozess [63] 1. Ordnung zugrunde liegt. Der Folgezustand \mathbf{x}_{k+1} hängt lediglich von seinem Ursprungszustand \mathbf{x}_k ab. Alle zeitlich zurückliegenden Messwerte \mathbf{Y}_k sind bereits im Ursprungszustand berücksichtigt. Es gilt

$$p(\mathbf{x}_{k+1} | \mathbf{x}_k, \mathbf{Y}_k) = p(\mathbf{x}_{k+1} | \mathbf{x}_k). \quad (5.9)$$

- Es wird angenommen, dass ein aktueller Messwert \mathbf{y}_{k+1} nur vom Augenblickswert des Systemzustandes \mathbf{x}_{k+1} abhängt. Es gilt

$$p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}, \mathbf{Y}_k) = p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}). \quad (5.10)$$

Mit den Gleichungen (5.6, 5.7, 5.9) und (5.10) lässt sich Gleichung (5.8) weiter umstellen zum rekursiven Bayes'schen Filteralgorithmus. Es gilt

$$p(\mathbf{x}_{k+1} | \mathbf{Y}_{k+1}) = \frac{\overbrace{p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1})}^{\text{Messwertaktualisierung}} \cdot \overbrace{\int p(\mathbf{x}_{k+1} | \mathbf{x}_k) \cdot p(\mathbf{x}_k | \mathbf{Y}_k) d\mathbf{x}_k}^{\text{Prädiktion}}}{\underbrace{\int p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}) \int p(\mathbf{x}_{k+1} | \mathbf{x}_k) \cdot p(\mathbf{x}_k | \mathbf{Y}_k) d\mathbf{x}_k d\mathbf{x}_{k+1}}_{\text{Normierung}}}. \quad (5.11)$$

Der Algorithmus lässt sich in die drei Schritte Prädiktion, Messwertaktualisierung und Normierung aufteilen. Um eine geschlossene algebraische Form angeben zu können, müssen die Integrale in Gleichung (5.11) unter der Vorgabe gewisser Randbedingungen an die Rauschprozesse sowie das wirkende Sensor- und Dynamikmodell gelöst werden. Der Bayes'sche Filteralgorithmus bildet die Grundlage für alle im Rahmen dieser Arbeit relevanten Schätzfilteralgorithmen [33] und darüber hinaus für den Großteil der in der Praxis zum Einsatz kommenden Verfahren im Bereich Umfeldmodellierung. Abb. 5.3 stellt die Erblinie des Filters für die im Folgenden erörterten Algorithmen dar.

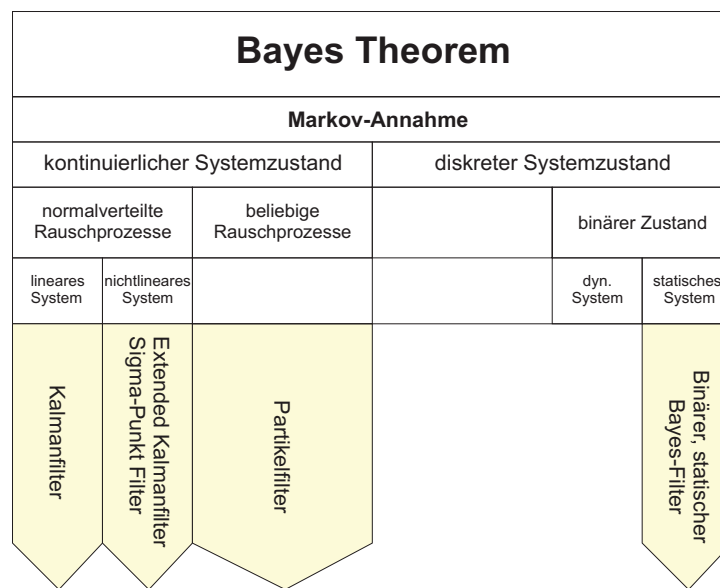


Abb. 5.3: Der Bayes'sche Filteralgorithmus und seine Varianten

5.2 Objektbasierte Umfeldmodellierung

Ausgangspunkt der objektbasierten Umfeldmodellierung ist die Beschreibung jedes Objekts durch den eindeutigen Zustandsvektor \mathbf{x} , der alle relevanten Objekteigenschaften beinhaltet. Es wird davon ausgegangen, dass die Messinformation eines Sensorsystems im Rahmen der Datenassoziation zu jedem Zeitpunkt eindeutig dem korrespondierenden Objekt des Umfeldmodells zugeordnet werden kann. Eine weitere Voraussetzung ist die Verfügbarkeit von direkten Messwerten, die keine Abhängigkeit zu zeitlich zurückliegenden Messungen aufweisen [3]. Der letzte Punkt ist unter Verwendung von objektgebenden Sensoren nur näherungsweise erfüllt, da diese im Allgemeinen über ihre interne Objektverfolgung bereits vorgefilterte Umfelddaten zur Verfügung stellen. Da üblicherweise für den Anwender über den genauen Ablauf der sensorinternen Objektverfolgung nichts oder nur wenig bekannt ist, muss eine Modellierung dieser Abhängigkeiten entfallen [114].

Auf Basis dieser Annahmen kann eine Schätzung des Objektzustandes gemäß des zuvor skizzierten Bayes'schen Filteralgorithmus erfolgen.

5.2.1 Prozessmodell im Zustandsraum

Man definiert zunächst das Prozessmodell des Objektes im Zustandsraum, das den Zusammenhang zwischen der Messinformation und dem Zustandsvektor bzw. die zeitliche Änderung

des Zustandsvektors beschreibt. Es gilt

$$\mathbf{x}_{k+1} = \mathbf{f}(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{q}_k \quad \text{und} \quad (5.12)$$

$$\mathbf{y}_{k+1} = \mathbf{h}(\mathbf{x}_{k+1}) + \mathbf{r}_{k+1}. \quad (5.13)$$

Hierbei ist

- \mathbf{x}_k der $n \times 1$ Zustandsvektor zum Zeitpunkt k ,
- \mathbf{u}_k der $k \times 1$ Eingangsvektor,
- \mathbf{y}_k der korrespondierende $m \times 1$ Messvektor des Sensorsystems,
- $\mathbf{f}(\mathbf{x}_k)$ die Übergangsfunktion des Zustandsvektors vom Zeitpunkt k auf den Zeitpunkt $k + 1$,
- $\mathbf{h}(\mathbf{x}_k)$ der Zusammenhang zwischen Mess- und Zustandsvektor,
- \mathbf{q}_k ein beliebiger $n \times 1$ Vektor des Systemrauschens und
- \mathbf{r}_k ein beliebiger $m \times 1$ Vektor des Messrauschens.

Es ergibt sich die in Abb. 5.4 gezeigte Darstellung des Systems. Im Rahmen der Umfeld-




Abb. 5.4: Systemmodell im Zustandsraum

wahrnehmung entspricht der Eingangsvektor \mathbf{u} beispielsweise dem Lenk- oder Bremsingriff durch den Fahrer eines verfolgten Zielfahrzeugs. Dieser ist nicht bekannt und wird daher im Folgenden vernachlässigt, so dass nur die Eigendynamik des beobachteten Objekts von Interesse ist.

Beobachtbarkeit

Um eine Schätzung des Systemzustandes durch die Bayes'sche Filtertheorie zu erlauben, müssen Übergangs- und Messfunktion das Kriterium der Beobachtbarkeit [96] erfüllen, das der linearen Beobachter-Theorie (Luenberger-Beobachter) aus der klassischen Regelungstechnik entnommen werden kann. Für ein lineares Zustandsraummodell mit skalarer Ausgangsgröße der Form

$$\mathbf{x}_{k+1} = \mathbf{F} \cdot \mathbf{x}_k \quad \text{und} \quad (5.14)$$

$$y_{k+1} = \mathbf{H} \cdot \mathbf{x}_{k+1} \quad (5.15)$$

lässt sich durch Transformation mit der Matrix \mathbf{V} der Eigenvektoren von \mathbf{F} eine Entkopplung der Zustandsgrößen [81] durch Diagonalisierung der Matrix \mathbf{F} erreichen. Es gilt

$$\begin{aligned} \mathbf{V} \cdot \tilde{\mathbf{x}} &= \mathbf{x} \quad \text{und somit} \\ \tilde{\mathbf{x}}_{k+1} &= \underbrace{\mathbf{V} \cdot \mathbf{F} \cdot \mathbf{V}^{-1}}_{\tilde{\mathbf{F}}} \cdot \tilde{\mathbf{x}}_k \quad \text{sowie} \\ \mathbf{y} &= \underbrace{\mathbf{V} \cdot \mathbf{H}}_{\tilde{\mathbf{H}}} \cdot \tilde{\mathbf{x}}. \end{aligned} \quad (5.16)$$

Die Diagonalisierung der neuen Systemmatrix $\tilde{\mathbf{F}}$ führt zu der in Abbildung 5.5 gezeigten Zustandsraumdarstellung. Es ist offensichtlich, dass in Anwesenheit von Defekten innerhalb

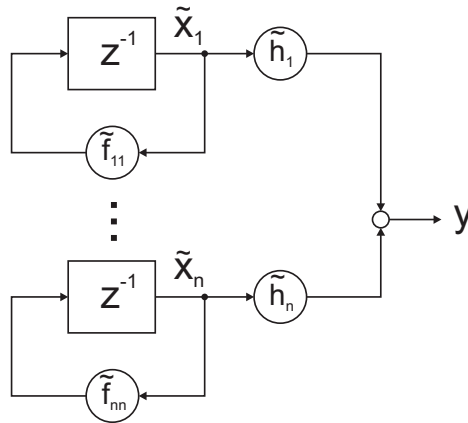


Abb. 5.5: Jordan-Normalform des Prozessmodells

der Ausgangsmatrix $\tilde{\mathbf{H}}$, d.h. $\tilde{h}_i = 0$ in Abb. 5.5 nicht vom Ausgang y auf die betreffende Zustandsgröße \tilde{x}_i zurückgerechnet werden kann. Die Zustandsgröße \tilde{x}_i ist in diesem Fall nicht

beobachtbar. Ohne den Umweg der Diagonalisierung führt diese Feststellung zur allgemeinen Definition der Beobachtbarkeit.

Definition 5.1 (Beobachtbarkeit) *Es System ist beobachtbar, wenn die Beobachtbarkeitsmatrix \mathbf{Q}_b , mit*

$$\mathbf{Q}_b = \begin{bmatrix} \mathbf{H} \\ \mathbf{HF} \\ \mathbf{HF}^2 \\ \dots \\ \mathbf{HF}^{n-1} \end{bmatrix}. \quad (5.17)$$

vollen Rang n aufweist.

Im Falle nichtlinearer Prozessmodelle werden die Matrizen \mathbf{F} und \mathbf{H} durch die linearisierten (Jacobi-) Matrizen der Systemübergangs- und Ausgangsfunktion $\mathbf{f}(\mathbf{x}_k)$ und $\mathbf{h}(\mathbf{x}_k)$ ersetzt.

5.2.2 Kalman Filter

Die Systembeschreibung im Zustandsraum ist Grundlage für die Herleitung bekannter Schätzverfahren aus dem Bayes'schen Filteralgorithmus. Eine geschlossene algebraische Lösung der Integrale in Gleichung (5.11) kann hierbei nicht für beliebige Systemübergangs- und Ausgangsfunktionen bestimmt werden.

Beim Kalman Filter beschränkt man sich daher auf die Betrachtung von linearen Systemen mit normalverteilten, stochastischen Rauschprozessen. Für die Initialisierung der a-priori Wahrscheinlichkeitsverteilung des Systemzustandes wird eine Normalverteilung um den Schätzwert $\hat{\mathbf{x}}$ mit bekannter Kovarianzmatrix $\hat{\mathbf{P}}$ angenommen. Das Prozessmodell vereinfacht sich unter diesen Annahmen zu

$$\begin{aligned} \mathbf{x}_{k+1} &= \mathbf{F}\mathbf{x}_k + \mathbf{q}_k \quad \text{und} \\ \mathbf{y}_{k+1} &= \mathbf{H}\mathbf{x}_{k+1} + \mathbf{r}_{k+1}. \end{aligned} \quad (5.18)$$

Für die Rauschprozesse und a-priori Verteilungsdichte des Systemzustands gilt:

$$p[\mathbf{x}] = N[\mathbf{x}; \hat{\mathbf{x}}, \hat{\mathbf{P}}] = \frac{1}{\sqrt{(2\pi)^N} \sqrt{|\hat{\mathbf{P}}|}} \cdot \exp\left(-\frac{1}{2}(\mathbf{x} - \hat{\mathbf{x}})^T \hat{\mathbf{P}}^{-1}(\mathbf{x} - \hat{\mathbf{x}})\right),$$

$$p[\mathbf{q}] = N[\mathbf{q}; 0, \mathbf{Q}] = \frac{1}{\sqrt{(2\pi)^N} \sqrt{|\mathbf{Q}|}} \cdot \exp\left(-\frac{1}{2}\mathbf{q}^T \mathbf{Q}^{-1}\mathbf{q}\right) \quad \text{und} \quad (5.19)$$

$$p[\mathbf{r}] = N[\mathbf{r}; 0, \mathbf{R}] = \frac{1}{\sqrt{(2\pi)^N} \sqrt{|\mathbf{R}|}} \cdot \exp\left(-\frac{1}{2}\mathbf{r}^T \mathbf{R}^{-1}\mathbf{r}\right). \quad (5.20)$$

Die Kovarianzmatrizen \mathbf{Q} und \mathbf{R} des System- und Messrauschens werden als bekannt vorausgesetzt. Für die einzelnen Stufen des Bayes'schen Filteralgorithmus ergibt sich folgende analytische Lösung:

- **Prädiktion:**

$$\int N[\mathbf{x}_{k+1}; \mathbf{F}\mathbf{x}_k, \mathbf{Q}] \cdot N[\mathbf{x}_k; \hat{\mathbf{x}}_k, \hat{\mathbf{P}}_k] d\mathbf{x}_k = N[\mathbf{x}_{k+1}; \mathbf{x}_{k+1}^*, \mathbf{P}_{k+1}^*]. \quad (5.21)$$

Wenn für die a-priori Wahrscheinlichkeitsverteilung des Systemzustandes eine Normalverteilung um den Schätzwert $\hat{\mathbf{x}}$ mit der Kovarianzmatrix $\hat{\mathbf{P}}$ gilt, so gilt auch für dessen Prädiktion auf Basis des linearen Systemmodells eine Normalverteilung um \mathbf{x}_{k+1}^* mit der Kovarianzmatrix \mathbf{P}_{k+1}^* . Diese berechnen sich zu

$$\begin{aligned} \mathbf{x}_{k+1}^* &= \mathbf{F}\hat{\mathbf{x}}_k \quad \text{und} \\ \mathbf{P}_{k+1}^* &= \mathbf{F}\hat{\mathbf{P}}_k\mathbf{F}^T + \mathbf{Q}. \end{aligned} \quad (5.22)$$

- **Messwertaktualisierung:**

Definitionsgemäß ist der Messvektor \mathbf{y} normalverteilt um den Zustandsvektor \mathbf{x} , da ein normalverteilter Rauschprozess \mathbf{r} angenommen wird. Es gilt:

$$p[\mathbf{y}_{k+1} | \mathbf{x}_{k+1}] = N[\mathbf{y}_{k+1}; \mathbf{H}\mathbf{x}_{k+1}, \mathbf{R}]. \quad (5.23)$$

- **Normierung:**

Die Normierung gemäß Glg. (5.11) ergibt sich als Integral über die bereits in den Gleichungen (5.21) und (5.23) bestimmten Größen. Man erhält

$$p[\mathbf{y}_{k+1} | \mathbf{Y}_k] = N[\mathbf{y}_{k+1}; \mathbf{H}\mathbf{x}_{k+1}^*, \mathbf{S}_{k+1}]. \quad (5.24)$$

\mathbf{S}_{k+1} ist die Kovarianzmatrix der Innovation, mit

$$\mathbf{S}_{k+1} = \mathbf{H}\mathbf{P}_{k+1}^*\mathbf{H}^T + \mathbf{R}. \quad (5.25)$$

Die mathematische Herleitung für die Lösung der Integrale über die Normalverteilungen in Gleichung (5.21), (5.23) und (5.24) kann z.B. [74, 120] entnommen werden. Es resultiert der rekursive Schätzalgorithmus des Kalmanfilters:

$$\mathbf{x}_{k+1}^* = \mathbf{F}\hat{\mathbf{x}}_k, \quad (5.26)$$

$$\mathbf{P}_{k+1}^* = \mathbf{F}\hat{\mathbf{P}}_k\mathbf{F}^T + \mathbf{Q}, \quad (5.27)$$

$$\vec{y}_{k+1}^* = \mathbf{H} \cdot \vec{x}_{k+1}^*, \quad (5.28)$$

$$\mathbf{S}_{k+1} = \mathbf{H}\mathbf{P}_{k+1}^*\mathbf{H}^T + \mathbf{R}, \quad (5.29)$$

$$\mathbf{K}_{k+1} = \mathbf{P}_{k+1}^*\mathbf{H}^T\mathbf{S}_{k+1}^{-1}, \quad (5.30)$$

$$\hat{\mathbf{x}}_{k+1} = \mathbf{x}_{k+1}^* + \mathbf{K}_{k+1} \cdot (\mathbf{y}_{k+1} - \mathbf{y}_{k+1}^*) \quad \text{und} \quad (5.31)$$

$$\hat{\mathbf{P}}_{k+1} = (\mathbf{I} - \mathbf{K}_{k+1}\mathbf{H})\mathbf{P}_{k+1}^*. \quad (5.32)$$

Dieses liefert den optimalen (Minimum Mean Squared Error) Schätzwert für den Systemzustand unter der Voraussetzung, dass alle Annahmen an die Natur des Prozessmodells erfüllt sind [6].

5.2.3 Erweitertes Kalmanfilter

In der Praxis ist ein lineares Prozessmodell oft nicht gegeben. Bildet man jedoch eine normalverteilte Zufallsvariable durch eine nichtlineare Funktion ab, so ist das Ergebnis nicht weiterhin normalverteilt, wie in Abb. 5.6 dargestellt ist.

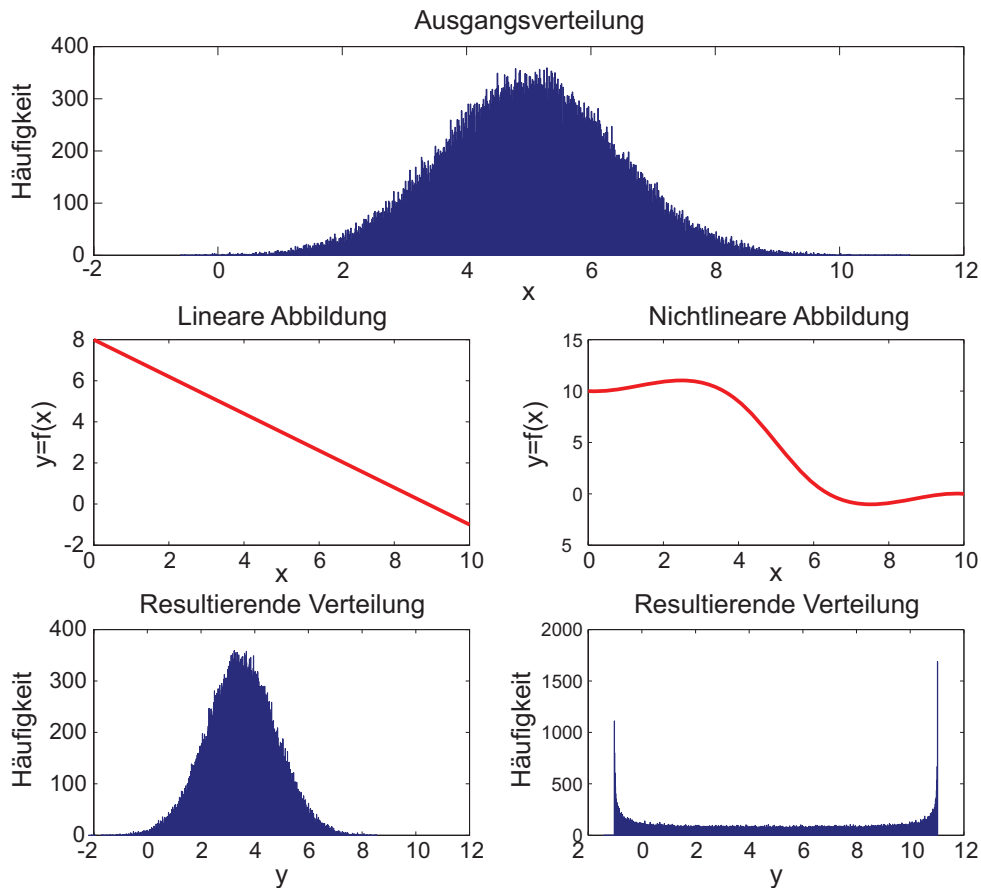


Abb. 5.6: Lineare und nichtlineare Transformation einer Normalverteilung

Für die Anwendung des Bayes'schen Filteralgorithmus bedeutet dies, dass eine geschlossen algebraische Lösung der Integrale wie in den Gleichungen (5.21), (5.23) und (5.24) nicht möglich ist. Beim erweiterten Kalmanfilter wird dieser Problematik durch Linearisierung um den aktuellen Schätzwert $\hat{\mathbf{x}}$ begegnet. Es ergibt sich für die linearisierten Gleichungen

$$\tilde{\mathbf{f}}(\mathbf{x}_k) \approx \mathbf{f}(\hat{\mathbf{x}}_k) + \mathbf{F}_k \cdot (\mathbf{x}_k - \hat{\mathbf{x}}_k) \quad (5.33)$$

$$\tilde{\mathbf{h}}(\mathbf{x}_{k+1}) \approx \mathbf{h}(\hat{\mathbf{x}}_{k+1}) + \mathbf{H}_{k+1} \cdot (\mathbf{x}_k - \hat{\mathbf{x}}_k). \quad (5.34)$$

Hierbei sind \mathbf{F}_k und \mathbf{H}_k die Jacobimatrizen der nichtlinearen Funktionen an der Stelle $\mathbf{x}_k = \hat{\mathbf{x}}_k$. Es gilt

$$\mathbf{F}_k = \left. \frac{\partial \mathbf{f}(\mathbf{x}_k)}{\partial \mathbf{x}_k} \right|_{\mathbf{x}_k = \hat{\mathbf{x}}_k} = \left[\begin{array}{ccc} \frac{f_1}{\partial x_1} & \cdots & \frac{f_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{f_n}{\partial x_1} & \cdots & \frac{f_n}{\partial x_n} \end{array} \right] \bigg|_{\mathbf{x}_k = \hat{\mathbf{x}}_k} \quad (5.35)$$

und

$$\mathbf{H}_k = \left. \frac{\partial \mathbf{h}(\mathbf{x}_k)}{\partial \mathbf{x}_k} \right|_{\mathbf{x}_k = \hat{\mathbf{x}}_k} = \left[\begin{array}{ccc} \frac{h_1}{\partial x_1} & \cdots & \frac{h_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{h_n}{\partial x_1} & \cdots & \frac{h_n}{\partial x_n} \end{array} \right] \bigg|_{\mathbf{x}_k = \hat{\mathbf{x}}_k}. \quad (5.36)$$

Durch die Linearisierung wird das Problem auf ein einfaches Kalmanfilter zurückgeführt. Es ergibt sich folgender Filteralgorithmus:

$$\begin{aligned} \mathbf{x}_{k+1}^* &= \mathbf{f}(\hat{\mathbf{x}}_k), \\ \mathbf{P}_{k+1}^* &= \mathbf{F}_k \hat{\mathbf{P}}_k \mathbf{F}_k^T + \mathbf{Q}, \\ \mathbf{y}_{k+1}^* &= \mathbf{h}(\mathbf{x}_{k+1}^*), \\ \mathbf{S}_{k+1} &= \mathbf{H}_{k+1} \mathbf{P}_{k+1}^* \mathbf{H}_{k+1}^T + \mathbf{R}, \\ \mathbf{K}_{k+1} &= \mathbf{P}_{k+1}^* \mathbf{H}_{k+1}^T \mathbf{S}_{k+1}^{-1}, \\ \hat{\mathbf{x}}_{k+1} &= \mathbf{x}_{k+1}^* + \mathbf{K}_{k+1} \cdot (\mathbf{y}_{k+1} - \mathbf{y}_{k+1}^*) \quad \text{und} \\ \hat{\mathbf{P}}_{k+1} &= (\mathbf{I} - \mathbf{K}_{k+1} \mathbf{H}_{k+1}) \cdot \mathbf{P}_{k+1}^*. \end{aligned} \quad (5.37)$$

Die Jacobi-Matrizen \mathbf{F}_k und \mathbf{H}_k müssen in jedem Zeitschritt k neu berechnet werden, wodurch sich ein entsprechend höherer Rechenzeitbedarf ergibt.

Es ist offensichtlich, dass der Ansatz der Linearisierung beim erweiterten Kalmanfilter zu Abbildungsfehlern führt, die den Erwartungswert und die Varianz der Zustandsschätzung negativ beeinflussen. Die Größe des Fehlers ist abhängig vom Grad der Nichtlinearität des Prozessmodells.

5.2.4 Sigma-Punkt Filtervarianten

Um die Abbildungsfehler zu minimieren, wurden verschiedene weiterführende Schätzfilter auf Basis des erweiterten Kalmanfilters entworfen [78], welche insbesondere im Bereich der Eigenlokalisation zum Einsatz kommen [26, 113]. Die unter dem Oberbegriff Sigma-Punkt-

Filter einzuordnenden Algorithmen erweitern die Zustandsschätzung auf die Betrachtung einer Reihe von Testvektoren (sog. Sigma-Punkte) aus der Wahrscheinlichkeitsverteilung des Systemzustandes. Aufgrund der Ähnlichkeit der verschiedenen Sigma-Punkt-Varianten soll hier lediglich das Unscented Kalmanfilter vorgestellt werden.

Man definiert zunächst $N = 2n + 1$ Sigma-Punkte $\chi^{(i)}$ als Stichproben aus der Zustandsraumverteilung zu:

$$\begin{aligned}\chi_k^0 &= \hat{\mathbf{x}}_k, \\ \chi_k^{(i)} &= \hat{\mathbf{x}}_k + \sqrt{(n + \kappa)} \cdot \sqrt{\hat{\mathbf{P}}_{k_i}} \quad \text{und} \\ \chi_k^{i+n} &= \hat{\mathbf{x}}_k - \sqrt{(n + \kappa)} \cdot \sqrt{\hat{\mathbf{P}}_{k_i}}.\end{aligned}\tag{5.38}$$

Jedem Sigma-Punkt wird ein Gewicht w^i zugeordnet. Es gilt

$$\begin{aligned}w^0 &= \frac{2\kappa}{2(n + \kappa)} \quad \text{und} \\ w^i = w^{i+n} &= \frac{1}{2(n + \kappa)}.\end{aligned}\tag{5.39}$$

Der Term $\sqrt{\hat{\mathbf{P}}_i}$ ist die i -te Spalte der Quadratwurzel der Schätzfehler-Kovarianzmatrix $\hat{\mathbf{P}}$, κ ein frei wählbarer Parameter für die Lage der Testpunkte und n die Dimension des Zustandsvektors. Es gilt hierbei

$$\hat{\mathbf{x}}_k = \sum_{i=1}^{N-1} w^{(i)} \chi_k^{(i)} \quad \text{und}\tag{5.40}$$

$$\hat{\mathbf{P}}_k = \sum_{i=1}^{N-1} w^{(i)} \left(\chi_k^{(i)} - \hat{\mathbf{x}}_k \right) \left(\chi_k^{(i)} - \hat{\mathbf{x}}_k \right)^T.\tag{5.41}$$

Zunächst werden die prädizierten Sigma-Punkte mit Hilfe der nichtlinearen Abbildung $\mathbf{f}(\mathbf{x}_k)$ bestimmt:

$$\chi_{k+1}^{*(i)} = \mathbf{f} \left(\chi_k^{(i)} \right).\tag{5.42}$$

Der prädizierte Systemzustand sowie die prädizierte Kovarianzmatrix ergeben sich zu

$$\mathbf{x}_{k+1}^* = \sum_{i=0}^{N-1} w^{(i)} \boldsymbol{\chi}_{k+1}^{*(i)} \quad \text{und} \quad (5.43)$$

$$\mathbf{P}_{k+1}^* = \sum_{i=0}^{N-1} w^{(i)} \left(\boldsymbol{\chi}_{k+1}^{*(i)} - \mathbf{x}_{k+1}^* \right) \cdot \left(\boldsymbol{\chi}_{k+1}^{*(i)} - \mathbf{x}_{k+1}^* \right)^T + \mathbf{Q}. \quad (5.44)$$

Durch die Streuung der Sigma-Punkte entlang der Wahrscheinlichkeitsverteilung des Systemzustandes ergibt sich eine optimierte Abdeckung des nichtlinearen Übertragungsverhaltens. Um den Einfluss des Systemrauschens \mathbf{Q} zu berücksichtigen, wird für den prädizierten Zustandsvektor \mathbf{x}_{k+1}^* mit der Kovarianzmatrix \mathbf{P}_{k+1}^* eine neue Sigma-Punkt-Verteilung mit $\boldsymbol{\chi}_{k+1}^{** (i)}$ unter Verwendung von Gleichung (5.38) erzeugt. Die auf diese Weise neu erzeugten Sigma-Punkte $\boldsymbol{\chi}_{k+1}^{** (i)}$ werden mit Hilfe der nichtlinearen Systemausgangsfunktion $\mathbf{h}(\mathbf{x})$ auf den erwarteten Messvektor abgebildet. Der prädizierte Messwert \mathbf{y}_{k+1}^* sowie dessen Kovarianzmatrix \mathbf{P}_{k+1}^{yy} berechnen sich zu:

$$\boldsymbol{\gamma}_{k+1}^{(i)} = \mathbf{h} \left(\boldsymbol{\chi}_{k+1}^{** (i)} \right), \quad (5.45)$$

$$\mathbf{y}_{k+1}^* = \sum_{i=0}^{N-1} w^{(i)} \boldsymbol{\gamma}_{k+1}^{(i)} \quad \text{und} \quad (5.46)$$

$$\mathbf{P}_{k+1}^{yy} = \sum_{i=0}^{N-1} w_i \left(\boldsymbol{\gamma}_{k+1}^{(i)} - \mathbf{y}_{k+1}^* \right) \cdot \left(\boldsymbol{\gamma}_{k+1}^{(i)} - \mathbf{y}_{k+1}^* \right)^T. \quad (5.47)$$

Darauf aufbauend lässt sich die Kreuzkovarianz \mathbf{P}^{xy} zwischen Mess- und Zustandsvektor berechnen. Es gilt

$$\mathbf{P}_{k+1}^{xy} = \sum_{i=0}^{N-1} w_i \left(\boldsymbol{\chi}_{k+1}^{(i)} - \mathbf{x}_{k+1}^* \right) \cdot \left(\boldsymbol{\gamma}_{k+1}^{(i)} - \mathbf{y}_{k+1}^* \right)^T. \quad (5.48)$$

Der verbleibende Prozess der Zustandsschätzung lässt sich auf das klassischen Kalmanfilter zurückführen. Es ergibt sich

$$\mathbf{S}_{k+1} = \mathbf{P}_{k+1}^{yy} + \mathbf{R}, \quad (5.49)$$

$$\mathbf{K}_{k+1} = \mathbf{P}_{k+1}^{xy} \cdot \mathbf{S}_{k+1}^{-1}, \quad (5.50)$$

$$\hat{\mathbf{x}}_{k+1} = \mathbf{x}_{k+1}^* + \mathbf{K}_{k+1} \cdot (\mathbf{y}_{k+1} - \mathbf{y}_{k+1}^*) \quad \text{und} \quad (5.51)$$

$$\hat{\mathbf{P}}_{k+1} = \mathbf{P}_{k+1}^* - \mathbf{K}_{k+1} \mathbf{S}_{k+1} \mathbf{K}_{k+1}^T. \quad (5.52)$$

Es ist anzumerken, dass insbesondere für die Sigma-Punkt-Schätzfilter eine erstaunliche Variantenvielfalt entwickelt worden ist. Die einzelnen Subtypen unterscheiden sich jedoch im Wesentlichen nur in der Wahl der Testvektoren und/oder der Modellierung des Prozess- und Messrauschens. Eine Einführung in die Dualität verschiedener Sigma-Punkt Schätzfilter liefert [76, 77].

5.2.5 Weiterführende Schätzverfahren und Auswahlkriterien

Auf Grundlage des Kalman-Algorithmus bzw. auf Grundlage der Bayes'schen Filtertheorie wurden eine Vielzahl von Varianten entwickelt, welche eine optimierte Zustandsschätzung für bestimmte Spezialfälle erlauben. Im Fokus stehen hierbei vor allem die Anpassung des Schätzalgorithmus auf verschiedene Bewegungsmodelle und/oder Zuordnungshypothesen sowie die Erweiterung der Zustandsschätzung auf beliebige, nicht-normalverteilte Schätzprobleme.

Multi-Modell-Schätzfilter

Das Interacting Multiple Model Filter (IMM) ermöglicht die Berücksichtigung mehrerer Bewegungsmodelle eines Ziels durch die parallele Berechnung eines separaten Schätzfilters (z.B. Kalmanfilter) für jedes Modell. Der Modellübergang wird als Markov-Kette modelliert, die Bestimmung der zu jedem Zeitpunkt gültigen Modellwahrscheinlichkeit ist Bestandteil des Schätzalgorithmus und wird über Bewertung der Innovationsterme aller unterlagerten Einzelmodellfilter realisiert. Es ergibt sich der in Abb. 5.7a dargestellte Ablauf. Charakteristisch für den Algorithmus sind die zusätzlichen Stufen zur Ein- und Ausgangsmischung. In diesen erfolgt ein Informationsaustausch zwischen den Einzelmodellfiltern, wobei die verschiedenen Schätzwerte über ihre Modellwahrscheinlichkeit gewichtet einfließen. Auf Einzelheiten des Algorithmus wird an dieser Stelle aus Gründen der Übersichtlichkeit verzichtet, eine umfassende Einführung liefert [61].

Mit der parallelen Berechnung mehrerer Schätzfilter ist beim IMM-Algorithmus ein entsprechender Rechenmehraufwand verbunden. Als vereinfachte Variante bietet sich das sog. Model-Switching Kalmanfilter an, bei der die Einzelmodell-Schätzfilter nicht parallel berechnet werden, sondern ein hartes Umschalten zwischen den Bewegungsmodellen erfolgt (vgl. 5.7b). Als Umschaltkriterium wird i.A. der zeitliche Mittelwert der normierten quadratischen Schätzfilterinnovation gemäß Gleichung (5.59) ausgewertet. Diese ist im Optimalfall (konsistente Zustandsschätzung) χ^2 -verteilt, Abweichungen von dieser Verteilung deuten auf

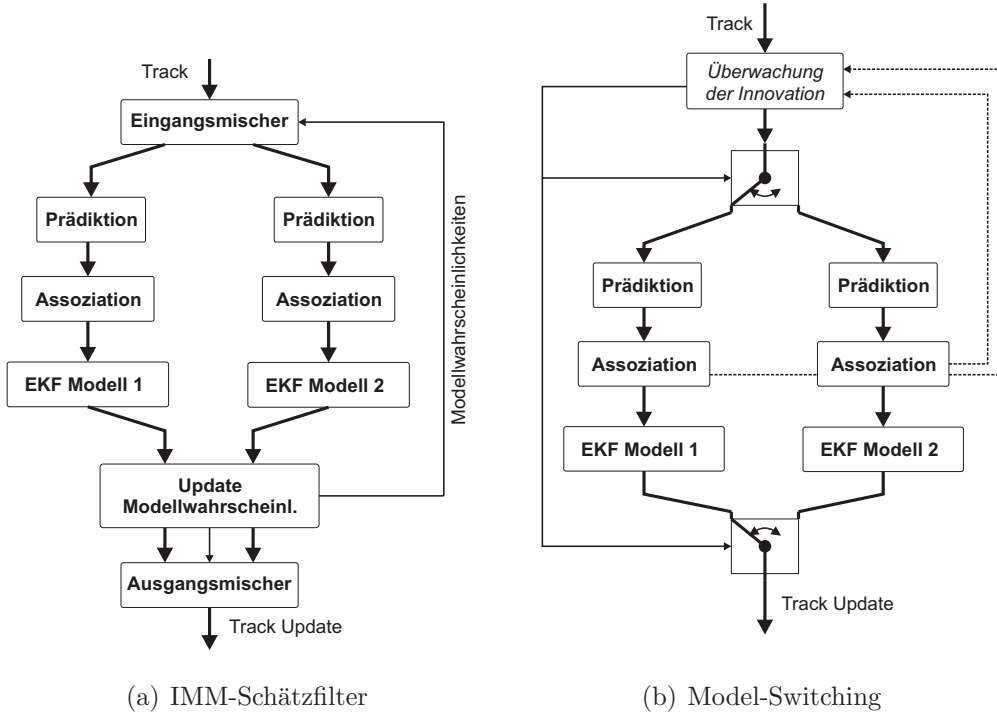


Abb. 5.7: Multimodell-Schätzfiltervarianten

eine Modellverletzung hin und können zum Wechsel zwischen den Schätzfiltern ausgenutzt werden [38].

Partikelfilter

Die für die verschiedenen Kalmanfilter-Varianten notwendige direkte analytische Lösung der Bayes'schen Filtergleichung setzt normalverteilte Rauschprozesse voraus, wodurch das Einsatzgebiet der daraus abgeleiteten Schätzfilter entsprechend begrenzt ist. Entfällt diese Beschränkung und ist daher keine analytische Lösung möglich, so kann alternativ eine Bestimmung der gesuchten a-posteriori Wahrscheinlichkeitsverteilung über das Prinzip der Monte-Carlo-Integration erfolgen. Beim Partikelfilter wird die Einzelinstanz des Zustandsvektors dazu ersetzt durch eine große Anzahl von Testvektoren. Die Gesamtheit aller Testvektoren approximiert nach dem Gesetz der großen Zahlen die Wahrscheinlichkeitsverteilung des Systemzustandes. Es lässt sich jede beliebige Verteilungsdichte approximieren. Es gilt

$$\hat{\mathbf{X}}_k = [\hat{\mathbf{x}}_k^1, \hat{\mathbf{x}}_k^2, \dots, \hat{\mathbf{x}}_k^N] \quad \text{mit} \quad p[\hat{\mathbf{X}}_k] = p[\mathbf{x}_k | \mathbf{Y}_k]. \quad (5.53)$$

Jeder möglichen Realisierung des Zustandsvektors wird ein skalares Gewicht w^i zugeordnet, das die Signifikanz des Partikels symbolisiert. Die Zustandsschätzung des Partikelfilters lässt sich in drei Phasen aufteilen.

- Zunächst werden alle Partikel mit Hilfe des beliebig gestaltbaren Prozessmodells prä-diziert.

$$\mathbf{x}_{k+1}^{i*} = \mathbf{f}(\hat{\mathbf{x}}_k^i) + \mathbf{q}_k \quad (5.54)$$

Insbesondere die Einflüsse von nichtidealen (nicht-normalverteilten) Rauschprozessen sowie multi-modale oder nichtparametrische Bewegungsmodelle [61] lassen sich auf diese Weise ohne größeren Zusatzaufwand integrieren.

- Nach der Prädiktion wird jedes Partikel unter Berücksichtigung seiner Nähe zum neu eingegangenen Messvektor gewichtet. Das Gewicht errechnet sich zu

$$w^i = p(\mathbf{y} | \mathbf{x}_{k+1}^{i*}) . \quad (5.55)$$

Es können beliebige Rauschprozesse im Rahmen des Sensormodells angenommen werden.

- Sind alle Gewichte w^i bestimmt, so erfolgt ein Neuaufbau der Partikelwolke. Bei konstant gehaltener Gesamtanzahl werden die Partikel entsprechend ihres Gewichtes in der Neuordnung dupliziert. Partikel mit geringem Gewicht können hierbei entfernt werden. Die resultierende Partikelwolke approximiert anschließend die gesuchte a-posteriori Wahrscheinlichkeitsverteilung des Systemzustandes.

Der Schätzprozess wird in Abb. 5.8 verdeutlicht. Aus der Partikelwolke lassen sich belie-

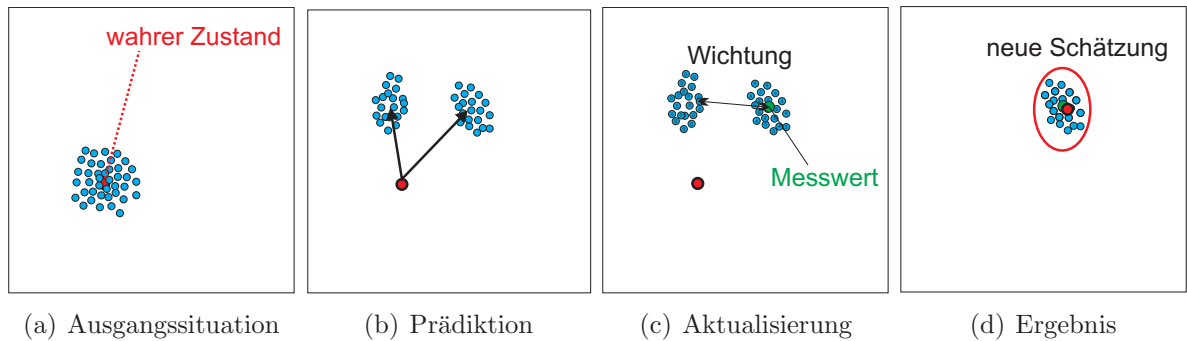


Abb. 5.8: Schätzvorgang des Partikelfilters

bige Schätzwerte ableiten (vgl. Abb. 5.2). Die Stärke des Partikelfilters ist seine Flexibili-

tät, die jedoch über die Anzahl der Partikel mit einem entsprechend hohen Rechenaufwand bezahlt wird. Lässt sich der Zustandsraum der Schätzung in normalverteilte und nicht-normalverteilte Zustandsgrößen aufteilen, so kann über das Prinzip der Rao-Blackwellisierten Monte-Carlo-Integration eine Mischform aus Kalman- und Partikelfilter geschaffen werden, wodurch sich die Anzahl der für die Schätzung notwendigen Partikel deutlich reduzieren lässt. In [115] wird eine praktische Anwendung dieser Vorgehensweise für die gleichzeitige Lösung des Datenzuordnungs- und Schätzproblems beschrieben.

Auswahlkriterien für die Umfeldwahrnehmung

Die zuvor vorgestellten Filteralgorithmen unterscheiden sich zum Teil erheblich bezüglich ihres Implementierungsaufwandes und Rechenzeitbedarfs. Das Partikelfilter ist zwar das flexibelste und leistungsfähigste Verfahren, jedoch kann es seine Vorteile nur bei ausgeprägten Nichtlinearitäten des Prozessmodells und/oder nichtidealen Rauschprozessen ausspielen.

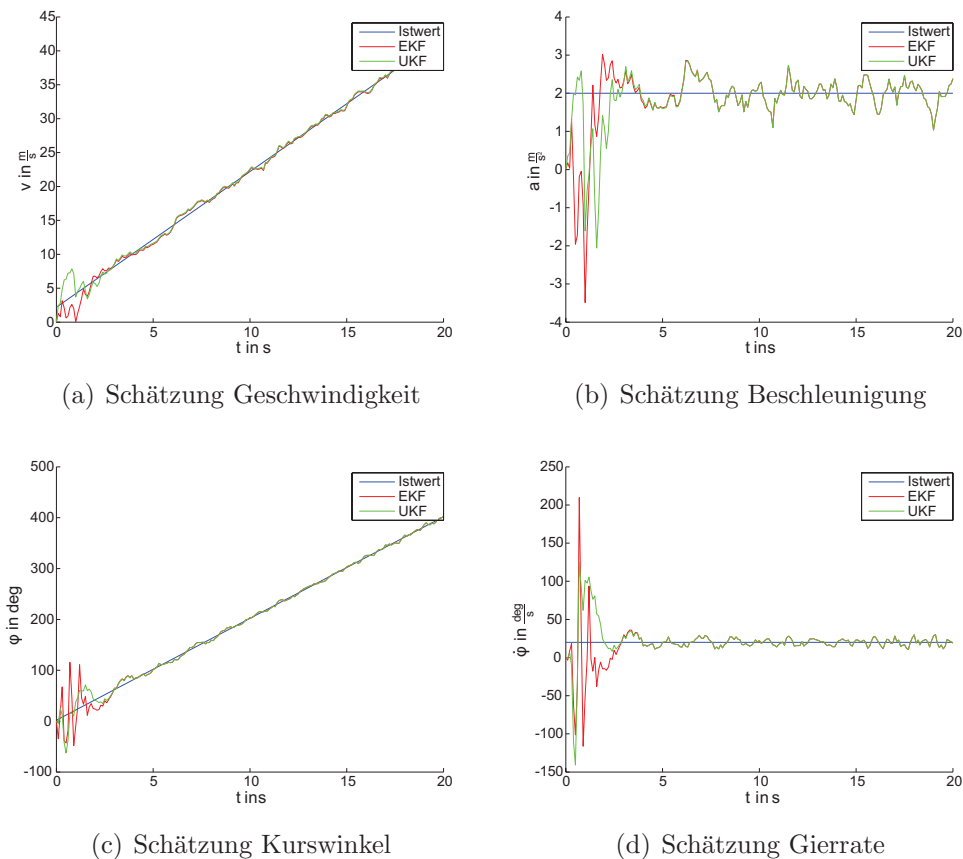


Abb. 5.9: Vergleich Schätzung EKF / UKF

Insbesondere die exakte Modellierung der wirkenden Rauschprozesse ist in der Praxis ein er-

hebliches Problem, da diese weder bekannt noch ohne größeren Aufwand messtechnisch quantifizierbar sind. Üblich ist eine Approximation durch Normalverteilungen, wodurch jedoch im Prinzip keine Notwendigkeit für die aufwendige Monte-Carlo-Integration mehr besteht. Zudem ist der Grad der Nichtlinearität der in der Praxis für die Umfeldwahrnehmung relevanten Dynamik- und Sensormodelle begrenzt. Bei einem Einsatz im Mehrziel-Betrieb muss weiterhin für jedes Objekt ein separater Schätzfilter mit der damit verbundenen Partikelanzahl betrieben werden. Dies ist für den Einsatz im urbanen Umfeld mit einer zu erwartenden hohen Objektanzahl nicht unproblematisch. Reduziert man die Partikelanzahl je Schätzfilter aufgrund der limitierten Rechenzeit, so nimmt die Güte der Approximation stark ab.

Für den Anwendungsfall der urbanen Objektverfolgung soll daher das Schätzverhalten des erweiterten Kalmanfilters mit dem der verbesserten Sigma-Punkt-Varianten verglichen werden. Als Prozessmodell des Objekt-Zustandsvektors wird das in Kapitel 6 näher spezifizierte Bewegungsmodell herangezogen, welches eine konstante Gierrate und Objektbeschleunigung voraussetzt. Die Simulationsergebnisse in Abb. 5.9 machen deutlich, dass sich nahezu identische Schätzergebnisse einstellen.

Der theoretisch nachweisbare Vorteil der aufwendigeren Sigma-Punkt-Linearisierung ist für die gegebene Problemstellung in der Praxis wenig relevant, so dass auf das erweiterte Kalmanfilter zurückgegriffen wird.

5.2.6 Objekttracking

Die rekursive Struktur der Bayes'schen Zustandsschätzung gibt den grundlegenden Ablauf für die Objektverfolgung (engl. Tracking [16, 17]) vor. Man erhält die in Abb. 5.10 dargestellten fünf elementare Schritte.

- Der Messzeitpunkt des Sensorsystems wird genutzt, um eine Prädiktion des Umfeldmodells auf die aktuelle Zeitscheibe vorzunehmen. Im Ergebnis liegen die Messdaten des Sensorsystems sowie die Objektdaten des Umfeldmodells in einem gemeinsamen zeitlichen Bezugssystem vor, so dass ein direkter Vergleich ermöglicht wird. Der korrekten Bestimmung des Messzeitpunktes kommt damit eine besondere Verantwortung für die Güte der Objektverfolgung zu.
- Das Sensorsystem arbeitet ohne Kenntnis des Umfeldmodells, im Falle einer Mehrziel-Anwendung muss daher ein Bezug zwischen den eingehenden Messdaten für verschiedene Ziele und deren Repräsentation im Umfeldmodell hergestellt werden. Liegen beide im selben zeitlichen Bezug vor, so kann ein Abgleich über das Sensormodell erfolgen. Im Rahmen der Datenassoziation wird zunächst für jeden prädizierten Zustandsvektor

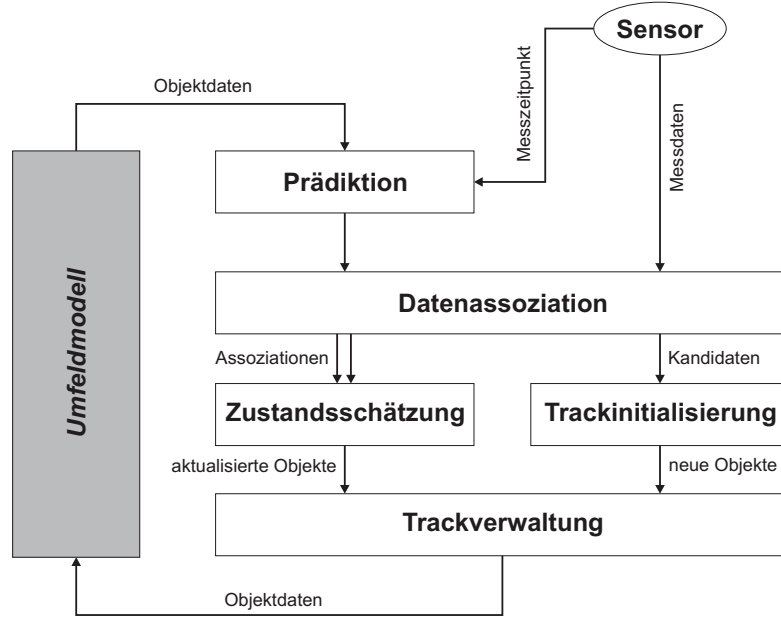


Abb. 5.10: Grundlegender Ablauf Objekttracking

\mathbf{x}^* der erwartete Messvektor \mathbf{y}^* bestimmt. Es gilt hierbei

$$\mathbf{y}_{k+1}^* = \mathbf{h}(\mathbf{x}_{k+1}^*), \quad (5.56)$$

Auf Basis des erwarteten Messvektors wird ein Ähnlichkeitswert $d(\mathbf{y}^*, \mathbf{y})$ zum tatsächlichen Messwert generiert. Die Definition dieser Ähnlichkeitsmetrik ist beliebig, jedoch muss diese folgenden Konventionen genügen:

$$\begin{aligned} d(\mathbf{y}^*, \mathbf{y}) &> 0 \quad \forall \quad \mathbf{y}^* \neq \mathbf{y} \quad \text{und} \\ d(\mathbf{y}^*, \mathbf{y}) &= 0 \quad \forall \quad \mathbf{y}^* = \mathbf{y}. \end{aligned} \quad (5.57)$$

Etabliert hat sich eine skalare Bewertung auf Basis eines m -dimensionalen Ellipsoiden, wobei m der Dimension des Messvektors entspricht. Man erhält:

$$d(\mathbf{y}^*, \mathbf{y}) = \sum_{i=1}^m \frac{1}{\alpha_i} \cdot (\mathbf{y}[i] - \mathbf{y}^*[i])^2. \quad (5.58)$$

Die frei definierbaren Parameter α_i bestimmen die Form und Ausdehnung der n_y -dimensionalen Hyperellipse, die Vektoren gleichen Ähnlichkeitsmaßes miteinander verbindet (vgl. Abb. 5.11). Üblich ist eine Wahl der α_i analog der Hauptdiagonalelemente der Innovationskovarianzmatrix \mathbf{S} aus Gleichung (5.25). Berücksichtigt man neben der




Abb. 5.11: Elliptisches Ähnlichkeitsmaß

Hauptdiagonale auch die Nebendiagonalen, so ergibt sich die in [16] angegebene normierte quadratische Innovation ϵ_ν als Abstandsmaß zu

$$d(\mathbf{y}^*, \mathbf{y}) = \epsilon_\nu = (\mathbf{y} - \mathbf{y}^*)^T \cdot \mathbf{S}^{-1} \cdot (\mathbf{y} - \mathbf{y}^*). \quad (5.59)$$

Sind alle Voraussetzungen für den Einsatz eines Kalmanfilters erfüllt (lineares System, normalverteilte Rauschprozesse), folgt ϵ_ν einer χ^2 -Verteilung mit m Freiheitsgraden. Kontinuierliches Abweichen der normierten quadratischen Innovation weist auf eine Inkonsistenz der Zustandsschätzung hin und kann zur Güteüberwachung und Manöverdetektion im Tracking-Algorithmus eingesetzt werden [4, 7].

Ziel der Datenzuordnung ist es, für jeden Zustandsvektor \mathbf{x} den korrekten Messvektor \mathbf{y} zu bestimmen, welcher für eine Zustandsschätzung in Frage kommt. Für das Bestimmen dieser Zuordnung sind eine ganze Reihe verschiedener Algorithmen in der Literatur beschrieben [12, 36, 108]. Zu unterscheiden sind hierbei

- Einfachzuordnungen (Abb. 5.12a), bei denen stets eine optimale Zuordnung gesucht wird,
- Mehrfachzuordnungen (Abb. 5.12b), bei denen mehrere Messvektoren für die Aktualisierung eines Objektzustandes herangezogen werden und
- Multi-Hypothesen Trackingfilter (Abb. 5.12c), bei denen für jede mögliche Zuordnung eine separate Instanz des Objekt-Zustandsvektors verfolgt wird.

Um den Aufwand der Zuordnung zu verringern ist es hierbei üblich, unwahrscheinliche Paarungen aus Mess- und Zustandsvektor durch Schwellwertüberwachung des Abstandsmaßes auszuschließen (engl. Gating).

- Ist die Datenassoziation abgeschlossen, so lassen sich die Messdaten in zwei Gruppen aufteilen. Der Anteil, für den eine gültige Assoziation zu einem bestehenden Objekt-Zustandsvektor ermittelt wurde, wird dem Zustandsschätzer zur Aktualisierung der

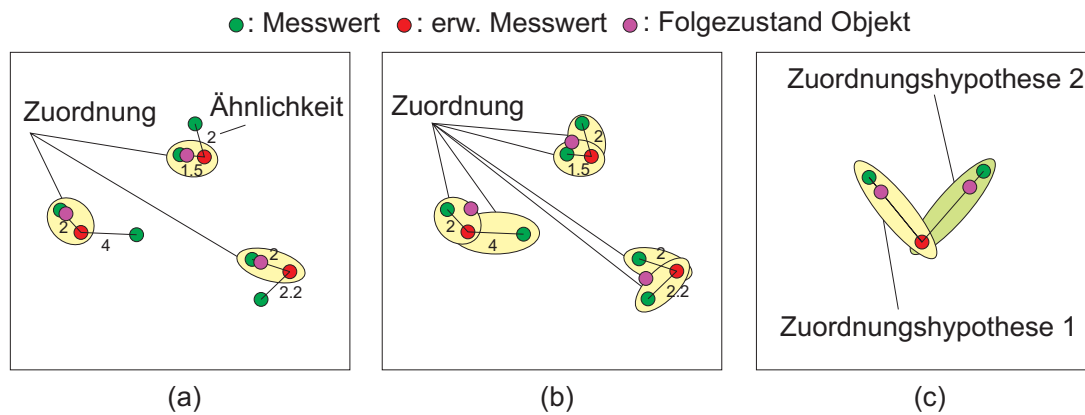


Abb. 5.12: Datenzuordnung und ihre Varianten

Objektdaten zugeführt. Der Anteil, für den keine gültige Assoziation ermittelt werden konnte, stellt potentiell ein neues (zuvor noch nicht beobachtetes) Objekt in der Fahrzeugumgebung dar und wird in die Trackinitialisierung überführt.

- Im Rahmen der Trackinitialisierung gilt es, durch Störungen erzeugte Fehlziele der Sensoren (sog. Geistermessungen) von korrekten Messungen eines neu im Umfeld vorhandenen Objektes zu unterscheiden. Im Falle eines Einzelsensorsystems kommt hierbei üblicherweise eine zeitliche Plausibilisierung zum Einsatz, d.h. eine Messung muss über mehrere Messzyklen hinweg stabil durch das Sensorsystem erzeugt worden sein. Im Falle von Mehrsensornetzwerken kann zusätzlich eine Plausibilisierung über redundante Beobachtungsbereiche für einen Ausschluss von Geistermessungen herangezogen werden.
- Als Abschluss des Objekttrackings werden die vorhandenen und neu initialisierten Objektdaten des Umfeldmodells einer Trackverwaltung zugeführt. Deren Aufgabe ist es Objekte zu identifizieren, für die keine neuen Messdaten eingehen. Diese haben den Beobachtungsbereich des Sensorsystems verlassen und müssen entsprechend aus dem Umfeldmodell entfernt werden.

Trackinitialisierung, Trackverwaltung und Datenassoziation kommen ein hohes Maß an Verantwortung für die Güte des resultierenden Umfeldmodells zu. Falsche oder fehlende Assoziationen führen zu einer inkonsistenten Zustandsschätzung und im Verlauf dessen zu einer fortwährenden Neuinitialisierung und Löschung von Objektdaten. Eine fehlerhafte Initialisierung sorgt ihrerseits wiederum für eine Störung der Datenassoziation, da unnötig erzeugte Objekte (falsche Alarme) mit den korrekten Objektdaten in Konkurrenz treten.

5.3 Kartenbasierte Umfeldmodellierung

Ausgangspunkt eines kartenbasierten Umfeldmodells ist die Diskretisierung des gesamten Beobachtungsbereiches in einzelne Zellen. Der mögliche Inhalt jeder einzelnen Zelle ist identisch und frei definierbar, in Analogie zur objektbasierten Darstellung ist dies der Zustandsraum der Karte, welche sich aus allen Zellen zusammensetzt. Die Umfeldkarte kann hierbei beliebige zweidimensionale [101], dreidimensionale [32, 117] oder auch mehrdimensionale [24, 25, 51] Räume abdecken. Da die Anzahl der Zellen exponentiell mit der Anzahl der Dimensionen ansteigt, sind allerdings vor allem zweidimensionale Karten in der Praxis relevant.

Definition 5.2 (2D-Karte) *Eine zweidimensionale Karte ist definiert durch*

- eine Menge \mathbf{Z} unabhängiger Zellen $z(i, j)$,
- die Anzahl M bzw. N der Zellen entlang der Kartendimensionen i und j ,
- den Bezugspunkt in kontinuierlicher Koordinatendarstellung $\begin{bmatrix} x_{ref} & y_{ref} \end{bmatrix}^T \in \mathbb{R}^2$,
- den Bezugspunkt in diskreter Koordinatendarstellung $\begin{bmatrix} i_{ref} & j_{ref} \end{bmatrix}^T \in \mathbb{N}^2$,
- die Auflösung der Karte entlang der kontinuierlichen Darstellung Δx und $\Delta y \in \mathbb{R}$ und
- die Abbildung $\Xi(x, y) \rightarrow (i, j)$.

Die Abbildung $\Xi(x, y)$ stellt den Bezug zwischen der Zellposition (i, j) in der Karte und dessen korrespondierender Position (x, y) bezüglich des realen Fahrzeugumfeldes her. Es werde hierbei davon ausgegangen, dass die X-Achse des Bezugskoordinatensystems in Richtung geografisch Ost, die Y-Achse in Richtung geografisch Nord zeigt. In Abb. 5.13 sind diese Zusammenhänge grafisch wiedergegeben, es wird dabei von kartesischen Koordinaten und parallelen Achsenrichtungen ausgegangen. Einzelheiten zu den verschiedenen im Rahmen dieser Arbeit verwendeten Koordinatendarstellungen finden sich in Anhang A.

5.3.1 Bayes'sche Belegungskarten

Belegungskarten gehen auf das in [41, 93] eingeführte Prinzip zurück, den Zustand der Umgebung lediglich durch die beiden Zustände *frei* und *belegt* zu modellieren. Eine Zelle $z(i, j)$ wird hierbei als frei betrachtet, wenn der durch sie beschriebene Umfeldbereich frei von




Abb. 5.13: Definition Umfeldkarte in 2D

Hindernissen ist und von einer autonomen mobilen Plattform ohne weiteres passiert werden kann. Es ergibt sich ein binärer Zustandsraum, der im Folgenden durch

$$\begin{aligned} z(i, j) = 0 & : \text{frei bzw.} \\ z(i, j) = 1 & : \text{belegt} \end{aligned} \quad (5.60)$$

definiert ist. Es gilt nun, den Belegungszustand der Karte so zu wählen, dass diese die größtmögliche Übereinstimmung mit den gesammelten Messdaten aufweist. Analog zur Vorgehensweise in Kapitel 5.1 wird die Problemstellung in eine probabilistische Beschreibung überführt. Gesucht ist die a-posteriori Wahrscheinlichkeitsverteilung der Gesamtkarte unter Berücksichtigung aller Messdaten \mathbf{Y} bis zum Zeitpunkt k mit

$$P[\mathbf{Z}|\mathbf{Y}_k] = P[z(1, 1), \dots, z(M, N)|\mathbf{Y}_k]. \quad (5.61)$$

Aus der Wahrscheinlichkeitsverteilung lässt sich die Karte mit der größten Verbundwahrscheinlichkeit ermitteln. Herausfordernd in Gleichung (5.61) ist die hohe Dimensionalität des Problems. Die explizite Berechnung der diskreten Wahrscheinlichkeitsverteilung über alle möglichen Karten ist praktisch nicht realisierbar, da sich bereits in der binären Belegt- / Freidarstellung $2^{M \times N}$ mögliche Karten ergeben.

Der Konflikt lässt sich lösen, indem man statistische Unabhängigkeit der einzelnen Zellen fordert. Jede beschreibt einen individuellen Umfeldabschnitt, dessen Zustand von dem seiner

Nachbarn nicht abhängt. Es gilt im Folgenden

$$\begin{aligned} P[z(i, j) = \text{frei}] &= P[\bar{z}(i, j)] \quad \text{und} \\ P[z(i, j) = \text{belegt}] &= P[z(i, j)]. \end{aligned} \quad (5.62)$$

Durch die Forderung einer statistischen Unabhängigkeit vereinfacht sich Gleichung (5.61) zu

$$P[z(1, 1), \dots, z(M, N) | \mathbf{Y}_k] = \prod_{i,j=1}^{M,N} P[z(i, j) | \mathbf{Y}_k]. \quad (5.63)$$

Durch die Vereinfachung zerfällt die komplexe Verbundwahrscheinlichkeit in das Produkt der Einzelwahrscheinlichkeiten aller Zellen. Diese lässt sich unabhängig von den jeweiligen Nachbarzellen leicht bestimmen.

5.3.2 Binärer Bayes Filter mit statischem Zustandsvektor

Für die Bestimmung der Belegtwahrscheinlichkeit wird der Bayes'sche Filteralgorithmus zum Einsatz gebracht. Gesucht ist die a-posteriori Belegtwahrscheinlichkeit einer Zelle zum Zeitpunkt $k + 1$,

$$P[z_{k+1} | \mathbf{y}_{k+1}, \mathbf{Y}_k, z_k, \dots, z_0] = P[z_{k+1} | \mathbf{y}_{k+1}, z_k]. \quad (5.64)$$

Es wird ein Markov-Prozess 1. Ordnung zugrunde gelegt, so dass alle Abhängigkeiten von Zellzuständen vor dem Zeitpunkt k entfallen. Die Anwendung von Gleichung (5.1) liefert

$$P[z_{k+1} = i | \mathbf{Y}_{k+1}] = \frac{P[\mathbf{y}_{k+1} | z_{k+1} = i, \mathbf{Y}_k] \cdot P[z_{k+1} = i | \mathbf{Y}_k]}{P[\mathbf{y}_{k+1} | \mathbf{Y}_k]}. \quad (5.65)$$

Da z eine diskrete Zufallsvariable ist, vereinfachen sich die Integrale der kontinuierlichen Bayes'schen Zustandsschätzung zu Summen. Es gilt:

$$\begin{aligned} P[z_{k+1} = i | \mathbf{Y}_k] &= \sum_{l=0}^1 P[z_{k+1} = i | z_k = l] \cdot P[z_k = l | \mathbf{Y}_k] \quad \text{und} \\ P[\mathbf{y}_{k+1} | \mathbf{Y}_k] &= \sum_{l=0}^1 P[\mathbf{y}_{k+1} | z_{k+1} = l, \mathbf{Y}_k] \cdot P[z_{k+1} = l | \mathbf{Y}_k]. \end{aligned} \quad (5.66)$$

Um die Lösung zu ermöglichen, wird eine weitere wesentliche Vereinfachung getroffen. Es wird davon ausgegangen, dass der Zellinhalt statisch ist, d.h. eine Zelle kann durch Eigendynamik ihren Zustand nicht ändern. Infolge dessen gilt

$$P[z_{k+1} = i | z_k = l] = \begin{cases} 1 & \text{für } l = i \\ 0 & \text{für } l \neq i \end{cases}. \quad (5.67)$$

Das Einsetzen von Gleichung (5.67) in Gleichung (5.66) ergibt

$$P[z_{k+1} = i | \mathbf{Y}_k] = P[z_k = i | \mathbf{Y}_k]. \quad (5.68)$$

Unter Verwendung der Markov-Eigenschaft lässt sich Gleichung (5.65) ferner vereinfachen zu

$$\begin{aligned} P[\mathbf{y}_{k+1} | z_{k+1} = i, \mathbf{Y}_k] &= P[\mathbf{y}_{k+1} | z_{k+1} = i] \quad \text{und} \\ P[y_{k+1} | \mathbf{Y}_k] &= \sum_{l=0}^1 P[\mathbf{y}_{k+1} | z_{k+1} = l] \cdot P[z_k = l | \mathbf{Y}_k]. \end{aligned} \quad (5.69)$$

Fügt man die Gleichungen (5.65), (5.66), (5.68) und (5.69) zusammen, so ergibt sich der binäre, statische Bayes-Filter zu

$$P[z_{k+1} = i | \mathbf{Y}_{k+1}] = \frac{\overbrace{P[\mathbf{y}_{k+1} | z_{k+1} = i]}^{\text{Messwertaktualisierung}} \cdot \overbrace{P[z_k = i | \mathbf{Y}_k]}^{\text{Prädiktion}}}{\underbrace{\sum_{l=0}^1 P[\mathbf{y}_{k+1} | z_{k+1} = l] \cdot P[z_k = l | \mathbf{Y}_k]}_{\text{Normierung}}}. \quad (5.70)$$

Für die weitere Anwendung des Filteralgorithmus erweist sich eine logarithmische Darstellung als günstiger. Man definiert die sog. Log-Odd Rate der Belegtwahrscheinlichkeit einer Zelle zu

$$l[z_k] = \log \frac{P[z_k]}{P[\bar{z}_k]} = \log \frac{P[z_k]}{1 - P[z_k]}. \quad (5.71)$$

Die Wahrscheinlichkeiten können aus der logarithmischen Darstellung rekonstruiert werden. Es gilt

$$P[z_k] = \frac{e^{l[z_k]}}{1 + e^{l[z_k]}} = 1 - \frac{1}{1 + e^{l[z_k]}}. \quad (5.72)$$

Mit Hilfe des Bayes'schen Gesetzes lässt sich die Belegtwahrscheinlichkeit unter Berücksichtigung des aktuellen Messwertes umformen. Es gilt

$$P[\mathbf{y}_{k+1} | z_{k+1}] = \frac{P[z_{k+1} | \mathbf{y}_{k+1}] \cdot P[\mathbf{y}_{k+1}]}{P[z_{k+1}]} \quad (5.73)$$

Teilt man Gleichung (5.70) durch die inverse Belegtwahrscheinlichkeit $p[\bar{z}_k | \mathbf{Y}_k]$ entfällt der aufwendige Normierungsterm und es ergibt sich

$$\frac{P[z_{k+1} | \mathbf{Y}_{k+1}]}{P[\bar{z}_{k+1} | \mathbf{Y}_{k+1}]} = \frac{P[z_{k+1} | \mathbf{y}_{k+1}]}{P[\bar{z}_{k+1} | \mathbf{y}_{k+1}]} \cdot \frac{P[z_k | \mathbf{Y}_k]}{P[\bar{z}_k | \mathbf{Y}_k]} \cdot \frac{P[\bar{z}_{k+1}]}{P[z_{k+1}]}, \quad (5.74)$$

bzw. in logarithmischer Darstellung

$$l[z_{k+1}] = \log \frac{P[z_{k+1} | \mathbf{y}_{k+1}]}{1 - P[z_{k+1} | \mathbf{y}_{k+1}]} + \log \frac{P[z_k | \mathbf{Y}_k]}{1 - P[z_k | \mathbf{Y}_k]} + \log \frac{P[\bar{z}_{k+1}]}{1 - P[\bar{z}_{k+1}]}. \quad (5.75)$$

Es ergibt sich ein rekursiver Filteralgorithmus für die Aktualisierung jeder Zelle, welcher sich aus drei Komponenten zusammensetzt:

$$l[z_{k+1}] = \underbrace{\log \frac{p[z_{k+1} | \mathbf{y}_{k+1}]}{1 - p[z_{k+1} | \mathbf{y}_{k+1}]}}_{\text{Messwertaktualisierung}} + \underbrace{\log \frac{p[\bar{z}_{k+1}]}{1 - p[\bar{z}_{k+1}]}}_{\text{A-priori Wissen}} + \underbrace{l[z_k]}_{\text{letzter Wert}} \quad (5.76)$$

- In der Messwertaktualisierung wird die Belegungswahrscheinlichkeit einer Zelle unter alleiniger Berücksichtigung des zuletzt eingegangenen Messwertes ausgenutzt. Diese Anwendung eines inversen Sensormodells ist reziprok zur Standardform des Bayes'schen Filteralgorithmus, der stets die Wahrscheinlichkeit eines Messwertes unter Berücksichtigung des Systemzustandes mit einfließen lässt. In der binären Darstellung des Belegungsgitters bietet die inverse Beschreibungsform Vorteile, da der Zustandsvektor der Zelle weit weniger komplex als der kontinuierliche Messvektor bzw. dessen Wahrscheinlichkeitsverteilung ist.
- Das a-priori Wissen beschreibt Vorkenntnisse über die Zellbelegung, die ohne Berücksichtigung von Messdaten angestellt werden können. An dieser Stelle kann beispielsweise zusätzliche Information aus digitalem Kartenmaterial mit eingebracht werden. Sind keine a-priori-Kenntnisse vorhanden, ergibt sich der Wert Null.
- Der letzte Wert ergibt sich durch die Belegungswahrscheinlichkeit der Zelle aus dem vorangegangenen Messzyklus.

Die in Kapitel 3.2.2 erwähnte Beschränkung der Belegungskarten auf eine statische Fahrzeugumgebung resultiert direkt aus den im Rahmen der Herleitung getroffenen Vereinfachungen (statistische Unabhängigkeit und statischer Zellzustand). Befinden sich bewegte Objekte innerhalb des Beobachtungsbereiches, so führen diese zu widersprüchlichen Eingangsdaten und zu einer verfälschten Kartendarstellung.

5.3.3 Einschränkungen der Bayes'schen Betrachtungsweise

Belegungskarten auf Basis des binären Bayes-Filters stoßen an ihre Grenzen, wenn konfliktbehaftete, unsichere oder unvollständige Messdaten in die Kartenerstellung einbezogen werden. Es ist die fundamentale Grundlage der Bayes'schen Darstellung, dass der Ereignisraum $\Omega = [A_1, \dots, A_n]$ vollständig ist. Jedem Elementarereignis A_i wird eine nicht negative Eintrittswahrscheinlichkeit zugeordnet. Es gilt der Satz der totalen Wahrscheinlichkeit mit

$$\sum_{i=1}^N P[A_i] = 1. \quad (5.77)$$

Dieses Prinzip der Vollständigkeit ist ebenfalls gültig für bedingte Wahrscheinlichkeiten, was bei der Verarbeitung von unsicheren Messdaten nicht unproblematisch ist. Sei B eine Beobachtung für das Ereignis A , so gilt stets

$$P[A|B] = 1 - P[\bar{A}|B]. \quad (5.78)$$

Die Beobachtung B wirkt sich auf den gesamten Ereignisraum Ω aus, auch wenn für das inverse Element \bar{A} keine Information eingegangen ist. In der Realität kann ein beliebiger, durch das Sensorsystem akquirierter Hinweis jedoch zu drei möglichen Aussagen führen:

- Der Hinweis stützt ein Ereignis $A \in \Omega$,
- der Hinweis stützt die Negation des Ereignisses, $\bar{A} \in \Omega$ oder
- der Hinweis stützt weder A noch dessen Negation \bar{A} , es ist keine Aussage möglich.

In einer naiven Implementierung scheitert die klassische Wahrscheinlichkeitstheorie bei der Modellierung der zuletzt geschilderten Situation. Bei der Anwendung des binären Bayes-Filters führt dies dazu, dass fehlendes Wissen und unsicheres Wissen nicht unterschieden werden können. Beide führen im Grenzfall zu einer Belegtwahrscheinlichkeit von 50 Prozent, wie in Abschnitt 5.3.6 anhand eines Beispiels geschildert wird.

5.3.4 Dempster-Shafer Theorie

Um die Möglichkeit der Entscheidungsfindung im Falle unsicherer Hinweise zu erweitern, wurde in den sechziger Jahren durch die Mathematiker Arthur P. Dempster und Glenn Shafer eine Basistheorie [31, 111] für das Arbeiten mit sog. Evidenzen entwickelt. Eine Evidenz ist als Indiz oder Beobachtung für oder auch wider eine beliebige Teilmenge des Ereignisraums Ω zu verstehen. Dieser besteht analog zur klassischen Wahrscheinlichkeitstheorie aus einer Menge von sich gegenseitig ausschließenden Elementarereignissen. Im Gegensatz zur Bayes'schen Modellierung wird allerdings nicht nur den Elementarereignissen selbst ein nichtnegatives Vertrauensmaß (Wahrscheinlichkeit) zugeordnet, sondern auch beliebigen Teilmengen. Eine gute Übersicht über die Möglichkeiten zum Umgang mit unsicheren Messdaten im Rahmen der Evidenztheorie geben [10, 11, 44]. Auf eine ausführliche mathematische Herleitung der Evidenztheorie wird aus Gründen der Übersichtlichkeit an dieser Stelle verzichtet, jedoch sollen die Schlüsselkonzepte und wichtigsten Definitionen angegeben werden.

Definition 5.3 (Basiswahrscheinlichkeit) *Sei Ω ein endlicher, vollständiger Ereignisraum, so heißt die Funktion $m : 2^\Omega \rightarrow [0, 1]$ Basiswahrscheinlichkeit / Wahrscheinlichkeitsmasse wenn gilt:*

$$\begin{aligned} m[\emptyset] &= 0 \quad \text{und} \\ \sum_{R \in \Omega} m[R] &= 1. \end{aligned} \tag{5.79}$$

Die Zuweisung eines numerischen Vertrauenswertes zu mehrelementigen Teilmengen R aus Ω ermöglicht direkt die Modellierung von Unsicherheiten.

Diese abstrakte Herangehensweise soll am Beispiel einer Urne mit unterschiedlich farbigen Kugeln (rot, grün, blau und gelb) konkretisiert werden. Eine mögliche Teilmenge des Ereignisraums ist

$$R = \{\text{rot}, \text{gelb}\}.$$

Es wurde also entweder eine rote oder eine gelbe Kugel gezogen. Diese Teilmenge aus Ω kann direkt mit einem numerischen Vertrauensmaß belegt werden, ohne die Wahrscheinlichkeit für das Elementarereignis rot bzw. grün zu quantifizieren.

Der Gültigkeitsbereich 2^Ω der Massenfunktion wird in diesem Zusammenhang auch Potenzmenge von Ω genannt, da er alle möglichen Teilmengen von Ω umfasst. Der leeren Menge

muss gemäß obiger Definition die Basiswahrscheinlichkeit Null zugeordnet werden, da Ω vollständig ist und somit keine Ereignisse $R \notin \Omega$ möglich sind.

Mit Hilfe der Basiswahrscheinlichkeit lassen sich zwei probabilistische Eckwerte ableiten:

Definition 5.4 (Belief und Plausibilität) *Es sei $m : 2^\Omega \rightarrow [0, 1]$ eine Basiswahrscheinlichkeit auf Ω .*

- *Das Gesamtmaß des Vertrauens in das Element $R \in \Omega$ sowie alle Teilmengen $S \in R$ wird quantifiziert durch die Belief-Funktion*

$$bl[R] = \sum_{S: S \subseteq R} m[S]. \quad (5.80)$$

- *Die Summe der Wahrscheinlichkeitsmasse, die potentiell dem Ereignis $R \in \Omega$ zugeordnet werden kann, wird quantifiziert durch die Plausibilitäts-Funktion*

$$pl[R] = \sum_{S: R \cap S \neq \emptyset} m[S]. \quad (5.81)$$

Die tatsächliche Wahrscheinlichkeit des Ereignisses R wird eingerahmt durch Belief und Plausibilität. Es gilt:

$$bl[R] \leq P[R] \leq pl[R]. \quad (5.82)$$

Ist es für den Beobachter möglich, vollständige Informationen zu erhalten, so ist die Wahrscheinlichkeitsmasse aller mehrelementigen Teilmengen aus Ω gleich Null und man erhält $bl[R] = pl[R] = P[R]$. Dies entspricht dem Anwendungsfall der klassischen Wahrscheinlichkeitstheorie. Das evidenzbasierte Schließen kann somit als Erweiterung zur klassischen Darstellung betrachtet werden.

Liegen unabhängige Beobachtungen für ein Ereignis vor, so lassen sich die Wahrscheinlichkeitsmassen zu einer resultierenden Gesamtmasse kombinieren [110].

Definition 5.5 (Dempster's Kombinationsgesetz) *Seien m_1 und m_2 die Basiswahrscheinlichkeiten unabhängiger Beobachter auf dem Ereignisraum Ω , so gilt für ihre Kombination $m_{1,2}$:*

$$m_{1,2}[R] = m_1[R] \oplus m_2[R] = \frac{\sum_{S_1, S_2: S_1 \cap S_2 = R \neq \emptyset} m_1[S_1] \cdot m_2[S_2]}{1 - \sum_{S_1, S_2: S_1 \cap S_2 = \emptyset} m_1[S_1] \cdot m_2[S_2]}. \quad (5.83)$$

Während des Kombinationsvorgangs lässt sich weiterhin der Konflikt C zwischen beiden Quellen quantifizieren. Es gilt:

$$C = \sum_{S_1, S_2: S_1 \cap S_2 = \emptyset} m_1[S_1] \cdot m_2[S_2]. \quad (5.84)$$

Durch die abstrakte Möglichkeit zur Kombination von Evidenzen unterschiedlicher Quellen wird die Evidenztheorie häufig im Bereich der Sensorfusion zum Einsatz gebracht.

Anwendungsbeispiel

Die vorangegangenen Definitionen sollen durch ein Anwendungsbeispiel verdeutlicht werden. Drei Personen bekommen für eine kurze Zeit eine Farbe gezeigt und sollen diese benennen. Die möglichen Aussagen seien hierbei rot, grün und blau ($\Omega = \{r, g, b\}$). Die drei Beobachter machen folgende Aussagen:

- (A) „Die Farbe war ziemlich sicher Rot, eventuell aber auch blau.“
- (B) „Die Farbe war mit großer Sicherheit nicht blau.“
- (C) „Möglicherweise war die Farbe Rot oder Blau, aber ich bin mir sehr unsicher.“

Um eine quantitative Bewertung zuzulassen, werden den drei Aussagen Wahrscheinlichkeitsmassen zugewiesen. Dempster's Kombinationsgesetz in Gleichung (5.83) ermöglicht anschließend die Bestimmung einer Gesamtaussage. Es zeigt sich, dass der größte Konsens der Beob-

$X \subseteq 2^\Omega$	m_A	m_B	m_C	$m_{A,B} = m_A \oplus m_B$	$m_{A,B,C} = m_{A,B} \oplus m_C$
\emptyset	0	0	0	0	0
$\{r\}$	0,7	0	0	0,77	0,83
$\{g\}$	0	0	0	0	0
$\{b\}$	0,1	0	0	0,01	0,01
$\{r, g\}$	0	0,9	0	0,2	0,14
$\{r, b\}$	0	0	0,3	0	0,01
$\{g, b\}$	0	0	0	0	0
$\{r, g, b\}$	0,2	0,1	0,7	0,02	0,02

Tabelle 5.1: Anwendungsbeispiel evidenzbasiertes Schließen

achter für die Farbe rot besteht. Die initiale Zuweisung der Wahrscheinlichkeitsmassen zu den Aussagen ermöglicht explizit die Modellierung von Unsicherheit über die mehrelementigen Teilmengen von Ω .

5.3.5 Belegungskarten auf Basis der Evidenztheorie

Es liegt nahe, die Dempster-Shafer Theorie auf den Anwendungsfall der Belegungskarten zu übertragen [94]. Über den binären Zellzustand ergibt sich die Potenzmenge 2^Ω zu

$$2^\Omega = \left\{ \begin{array}{l} \emptyset \\ B \\ F \\ \{B, F\} = U \end{array} \right\} \begin{array}{l} \text{(leere Menge)} \\ \text{(belegt)} \\ \text{(frei)} \\ \text{(unbekannt / keine Aussage).} \end{array} \quad (5.85)$$

Die mehrelementige Teilmenge $\{B, F\}$ ermöglicht eine direkte Quantifizierung des Unwissens.

Analog zur Bayes'schen Belegungskarte wird von statistisch unabhängigen und statischen Zellen ausgegangen, so dass die Massenverteilung jeder einzelnen Zelle separat bestimmbar ist. Für die Aktualisierung einer Zelle wird die Kombinationsregel aus Gleichung (5.83) zum Einsatz gebracht. Es ergibt sich als resultierende Massenverteilung m_{k+1} nach Berücksichtigung eines Messwertes \mathbf{y}_{k+1} zum Zeitpunkt $k + 1$

$$\begin{aligned} m_{k+1}[B] &= \frac{m_k[B] \cdot m_{\mathbf{y}_{k+1}}[B] + m_k[U] \cdot m_{\mathbf{y}_{k+1}}[B] + m_k[B] \cdot m_{\mathbf{y}_{k+1}}[U]}{1 - m_k[B] \cdot m_{\mathbf{y}_{k+1}}[F] - m_k[F] \cdot m_{\mathbf{y}_{k+1}}[B]}, \\ m_{k+1}[F] &= \frac{m_k[F] \cdot m_{\mathbf{y}_{k+1}}[F] + m_k[U] \cdot m_{\mathbf{y}_{k+1}}[F] + m_k[F] \cdot m_{\mathbf{y}_{k+1}}[U]}{1 - m_k[B] \cdot m_{\mathbf{y}_{k+1}}[F] - m_k[F] \cdot m_{\mathbf{y}_{k+1}}[B]} \quad \text{und} \\ m_{k+1}[U] &= 1 - m_{k+1}[B] - m_{k+1}[F]. \end{aligned} \quad (5.86)$$

Das inverse Sensormodell gemäß Abschnitt 5.3.2 überführt den Messwert \mathbf{y}_{k+1} in die äquivalente Massenverteilung $m_{\mathbf{y}_{k+1}}$.

5.3.6 Vergleich der Bayes- und Dempster-Shafer-Methodik

Die Anwendung der Dempster-Shafer-Theorie ermöglicht eine Unterscheidung von unsicheren und fehlenden Wissen in der Kartendarstellung sowie die Quantifizierung eines Datenkonfliktes. Dies ist in der Bayes'schen Darstellungsform nicht möglich, wie in Tabelle 5.2 anhand eines konkreten Rechenbeispiels erläutert wird.

Binärer Bayes Filter:	Dempster-Shafer:
Es wird begonnen mit einer Karte ohne Informationsinhalt. Für die Zelle m zum Zeitpunkt 0 gilt:	
$P[z_0] = 0.5$ $l[z_0] = 0$	$m_{z_0}[B] = 0$ $m_{z_0}[F] = 0$ $m_{z_0}[U] = 1$
Die erste Messung des Sensors geht ein, dieser ermittelt für die Zelle eine Belegtwahrscheinlichkeit von 90 %:	
$P[z_1 y_1] = 0.9$ $\log \frac{P[z_1 y_1]}{1-P[z_1 y_1]} = +0.95$	$m_{y_1}[B] = 0.9$ $m_{y_1}[F] = 0$ $m_{y_1}[U] = 0.1$
Die erste Messung wird in die Karte integriert. Es sind keine a-priori Kenntnisse über die Umwelt vorhanden.	
Gleichung (5.76)	Gleichung (5.86)
Ergebnis:	
$l[z_1] = +0.95$ $P[z_1] = 0.9$	$m_{z_1}[B] = 0.9$ $m_{z_1}[F] = 0$ $m_{z_1}[U] = 0.1$
Die zweite Messung des Sensors geht ein, dieser ermittelt für die Zelle eine Freiwahrscheinlichkeit von 90 %:	
$P[z_2 y_2] = 0.1$ $\log \frac{P[z_2 y_2]}{1-P[z_2 y_2]} = -0.95$	$m_{y_2}[B] = 0$ $m_{y_2}[F] = 0.9$ $m_{y_2}[U] = 0.1$
Die zweite Messung wird in die Karte integriert.	
Gleichung (5.76)	Gleichung (5.86)
Ergebnis:	
$l[z_2] = +0.95 - 0.95 = 0$ $P[z_2] = 0.5$	$m_{z_2}[B] = 0.47$ $m_{z_2}[F] = 0.47$ $m_{z_2}[U] = 0.06$

Tabelle 5.2: Vergleich Bayes - Dempster Shafer

Am Ende des Bayes'schen Filteralgorithmus ergibt sich kein Informationsgewinn zum Ausgangszustand ($P[z_0] = P[z_2] = 0.5$), obwohl Messinformation verarbeitet wurde. Demgegenüber steht die Darstellung gemäß Dempster Shafer. Zum Einen ist hier erkennbar, dass

Messinformationen verarbeitet wurden ($m_{z_0}[U] < m_{z_2}[U]$). Zum anderen lässt sich aufgrund der widersprüchlichen Gesamtaussage erkennen, dass konfliktbehaftete Messdaten zugrunde lagen. Das genaue Maß des Konfliktes lässt sich hierbei in jedem Filterzyklus gemäß Gleichung (5.84) bestimmen.

5.4 Sensorfusion

Die Integration von Daten mehrerer Sensorsysteme mit gemeinsamem Beobachtungsbereich erfordert eine Erweiterung der zuvor vorgestellten Algorithmen, da deren Ableitung aus dem Bayes'schen Filteralgorithmus zunächst von einer einzelnen Informationsquelle ausgeht. In Abhängigkeit des gewählten Umfeldmodells sind hierbei unterschiedliche Strategien möglich, über die im Folgenden ein kurzer Überblick gegeben werden soll.

5.4.1 Objektbasierte Sensorfusion

Der Fusion mehrerer Messgeber im Rahmen einer objektbasierten Zielverfolgung widmen sich eine Vielzahl von Veröffentlichungen aus dem Militär- und Zivilbereich [12, 57, 66, 67, 83, 92, 114]. Zu unterscheiden sind parallele und sequenzielle Fusionsvarianten in Abhängigkeit davon, ob die Messdaten mehrerer Sensoren gleichzeitig oder nacheinander in den Prozess der Zustandsschätzung eingebracht werden.

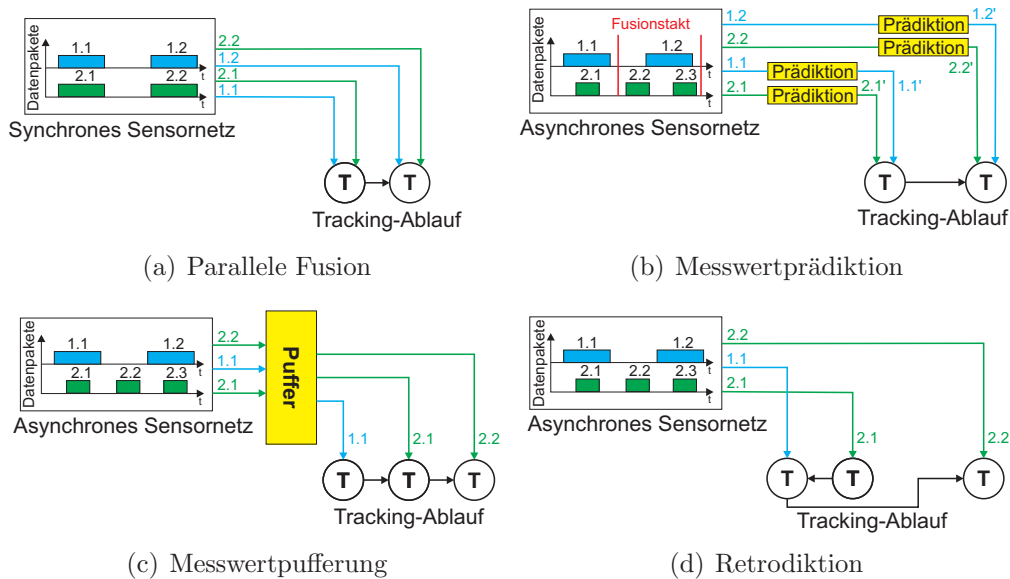


Abb. 5.14: Ablaufstrategien der Objektfusion

- Die parallele Sensorfusion eignet sich vor allem dann, wenn die Messdaten aller Sensoren stets zu einem einheitlichen Zeitpunkt vorliegen (synchrones Sensornetzwerk, vgl. 5.14a). Die gleichzeitige Verarbeitung mehrerer gültiger Messwerte im Rahmen der Zustandsschätzung erfordert eine Erweiterung der Schätzfilteralgorithmen. Hierfür ist insbesondere das in [12] vorgestellte Informationsfilter als duale Darstellung des klassischen Kalmanfilters prädestiniert.

Es ist leider festzustellen, dass zum derzeitigen Stand der Technik eine Synchronisation verschiedener Sensorsysteme im Automobilbereich aufgrund der eingesetzten Kommunikationssysteme und Komponenten unterschiedlicher Hersteller oft nicht realisierbar ist. In [12] wird deshalb ein fester Fusionstakt eingeführt und die asynchron eintreffenden Messdaten auf den Fusionszeitpunkt prädiert (vgl. Abb. 5.14b). Die zeitliche Prädiktion der Messdaten setzt allerdings zumindest die (Teil-)Messung der Objektdynamik voraus. Da der Einzelsensor im Normalfall weniger Informationen über die Objektdynamik zur Verfügung hat als das fusionierte Umfeldmodell, ergibt sich durch die unvermeidlichen Prädiktionsfehler jedoch eine Verschlechterung der Schätzgenauigkeit.

- Ist eine nachträgliche Synchronisation der Messdaten nicht möglich oder sinnvoll, so wird die sequenzielle Datenfusion zum Einsatz gebracht. Die erfordert nur minimale Modifikationen des klassischen Tracking-Konzeptes, da die Zustandsschätzungen nacheinander mit jeweils angepasstem Sensormodell erfolgen können. Besonderes Augenmerk ist geboten, wenn es aufgrund der asynchronen Arbeitsweise der Sensoren sowie der unvermeidbaren Übertragungslatenzen zu Störungen in der Empfangsreihenfolge der Messinformation kommt. Unter Umständen führt dies dazu, dass ein neu eingehendes Messdatum zeitlich vor dem zuletzt verarbeiteten Messwert in das Tracking-System eingebracht werden muss. In diesem Fall kann eine Prädiktion der Zustandsvektoren in die Vergangenheit erfolgen (Retrodiktion, vgl. Abb. 5.14d), so dass die Messinformation nachträglich in den Prozess der Zustandsschätzung mit eingebracht wird [5, 8]. Problematisch ist hierbei der Einfluss der Trackinitialisierung und Trackverwaltung, unter Umständen wurde ein Objekt bereits aus dem Umfeldmodell entfernt, so dass die „verspäteten“ Messdaten de facto „zu spät“ eintreffen.

In der Praxis [114] wird deshalb i.A. auf ein Konzept zur Pufferung der Messdaten zurückgegriffen, um die korrekte zeitliche Reihenfolge der einzelnen Messwerte zu rekonstruieren (vgl. Abb. 5.14c). Da bei der Sortierung jeweils auf den langsamsten Sensor gewartet werden muss, ergibt sich allerdings eine höhere Latenz des Trackingsystems, welche in Kauf genommen werden muss.

5.4.2 Kartenbasierte Sensorfusion

Stehen mehrere Messgeber als Informationsquelle für das kartenbasierte Umfeldmodell zur Verfügung, so müssen die Messdaten in geeigneter Weise fusioniert werden. Beispiele hierfür finden sich in [14, 129]. Es existieren hierzu prinzipiell zwei verschiedene Varianten:

- In der simpelsten Form lassen sich die Messdaten direkt in einer einzelnen, gemeinsamen Kartendarstellung fusionieren [62, 129]. Die Aktualisierung der Kartendarstellung erfolgt nacheinander in der Reihenfolge der von den Sensoren eingehenden Messungen analog dem oben skizzierten Prinzip der sequenziellen Sensorfusion. Liegen gleichartige Sensoren vor und arbeiten diese im gleichen Takt, so sind keine weiteren Schritte notwendig.
- Besonderes Augenmerk ist allerdings im Falle asynchroner Sensornetze geboten, wenn unterschiedliche Zykluszeiten einzelner Sensorsysteme bestehen. Die Integration der Messinformation in einem gemeinsamen Zell-Zustandsraum führt in diesem Fall dazu, dass der Messgeber mit der höchsten Messfrequenz die Gestalt der Karte dominiert. Es ergibt sich eine Abhängigkeit des Fusionsergebnisses von der Messfrequenz, welche in jedem Falle ungünstig ist. Diese Problematik lässt sich umgehen, indem zunächst für jeden Sensor eine separate Kartendarstellung erzeugt wird und die einzelnen Kartendarstellungen erst anschließend der Datenfusion zugeführt werden. Die zeitliche Integration der Messinformation erfolgt somit für jeden Sensor getrennt, wodurch die ungünstige Abhängigkeit von der Messfrequenz entfällt. Die Kombination der einzelnen Kartendarstellungen lässt sich hierbei durch das Prinzip der Bayes'schen Fusion [74] leicht realisieren:

$$P[z_k | \mathbf{Y}_k^{S1}, \mathbf{Y}_k^{S2}] = \frac{P[\mathbf{Y}_k^{S1}, \mathbf{Y}_k^{S2} | z_k] \cdot P[z_k]}{P[\mathbf{Y}_k^{S1}, \mathbf{Y}_k^{S2} | z_k] \cdot P[z_k] + P[\mathbf{Y}_k^{S1}, \mathbf{Y}_k^{S2} | \bar{z}_k] \cdot P[\bar{z}_k]}. \quad (5.87)$$

Unter der Annahme unabhängiger Messgeber lässt sich Gleichung (5.87) wie folgt umstellen:

$$\begin{aligned} P[z_k | \mathbf{Y}_k^{S1}, \mathbf{Y}_k^{S2}] &= \frac{P[\mathbf{Y}_k^{S1} | z_k] \cdot P[\mathbf{Y}_k^{S2} | z_k] \cdot P[z_k]}{P[\mathbf{Y}_k^{S1} | z_k] \cdot P[\mathbf{Y}_k^{S2} | z_k] \cdot P[z_k] + P[\mathbf{Y}_k^{S1} | \bar{z}_k] \cdot P[\mathbf{Y}_k^{S2} | \bar{z}_k] \cdot P[\bar{z}_k]} \\ &= \frac{P[z_k | \mathbf{Y}_k^{S1}] \cdot P[z_k | \mathbf{Y}_k^{S2}]}{P[z_k | \mathbf{Y}_k^{S1}] \cdot P[z_k | \mathbf{Y}_k^{S2}] + P[\bar{z}_k | \mathbf{Y}_k^{S1}] \cdot P[\bar{z}_k | \mathbf{Y}_k^{S2}] \cdot \frac{P[z_k]}{P[\bar{z}_k]}}. \end{aligned} \quad (5.88)$$

Für die a-priori Wahrscheinlichkeit der Zellbelegung wird der Wert maximaler Entropie (maximale Unsicherheit) angesetzt [104]. Es gilt daher $P[z_k] = P[\bar{z}_k] = 0.5$. Man erhält

für die fusionierte Kartendarstellung:

$$P[z_k | \mathbf{Y}_k^{S1}, \mathbf{Y}_k^{S2}] = \frac{P[z_k | \mathbf{Y}^{S1}] \cdot P[z_k | \mathbf{Y}^{S2}]}{P[z_k | \mathbf{Y}^{S1}] \cdot P[z_k | \mathbf{Y}^{S2}] + P[\bar{z}_k | \mathbf{Y}^{S1}] \cdot P[\bar{z}_k | \mathbf{Y}^{S2}]} \quad (5.89)$$

Wird anstelle der Bayes'schen Modellierung die in Kapitel 5.3.4 vorgestellte Evidenztheorie zum Einsatz gebracht, lassen sich die unabhängigen Karten über die in Gleichung (5.83) angegebene Kombinationsregel fusionieren.

6 Objekttracking in urbaner Umgebung

Die in Kapitel 4.2 eingeführte Notwendigkeit zur Beschreibung vielfältiger statischer und dynamischer Strukturen im Fahrbahn- und Randbereich motiviert die Entwicklung eines flexiblen Objektmodells, welches zur Beschreibung beliebiger Formen geeignet ist. Hierzu wird das Konzept einer kartenbasierten Umfeldbeschreibung aufgegriffen und kombiniert mit der klassisch zustandsbasierten Schätzung der Objektdynamik.

6.1 Objektmodell auf Basis lokaler Karten

Prinzipiell wird die Objektdarstellung erweitert um eine lokale Objektkarte, deren Bewegung bezüglich des Referenz-Koordinatensystems durch einen fest verbundenen Dynamikvektor ausgedrückt wird (vgl Abb. 6.1). Es gilt, auf Basis eingehender Messdaten die lokale Ob-




Abb. 6.1: Konzept der lokalen Objektkarte

jektkarte um die Konturinformationen des Objektes anzureichern und parallel die zeitliche Veränderung der Position zu nutzen, um eine Schätzung des Dynamikvektors zu ermöglichen.

Die Darstellung in Abb. 6.1 stellt dabei den Idealfall einer möglichen Implementierung dar, in der Praxis ergeben sich allerdings eine Reihe von Herausforderungen:

- Insbesondere für ausgedehnte Objekte wird eine entsprechend große lokale Karte benötigt. Da ausgedehnte Objekte üblicherweise nicht sofort als Ganzes durch eines oder mehrere Sensorsysteme erfasst werden, ergibt sich zudem die Notwendigkeit, die Dimension der Karte über die Beobachtungszeit hinweg anzupassen.
- Um zwischen neuen Konturinformationen und der Bewegung bekannter Konturbestandteile von einer Zeitscheibe auf die nächste zu unterscheiden, ist ein komplexer Datenabgleich (z.B. zweidimensionale Kreuzkorrelation) zwischen der bestehenden Karte und neu eingehenden Messdaten erforderlich. Der hierzu erforderliche Rechenaufwand ist entsprechend hoch.
- Die zur Verfügung stehenden Sensorsysteme mit Konturauflösung (z.B. LIDAR) ermöglichen lediglich eine Messung der zugewandten Reflexionskante eines Objektes. Verdeckte Bereiche sind zwar durch die Karte darstellbar, jedoch können diese entsprechend nicht mit ausreichender Messinformation belegt werden.
- Die Übermittlung kompletter Kartensätze für die Gesamtheit aller Objekte im Umfeldmodell an übergeordnete Algorithmen (vgl. Abschnitt 4) verursacht einen entsprechend hohen Bedarf an Kommunikationsbandbreite, welcher im Automobil nur schwer realisiert werden kann.

Um einen Einsatz in Echtzeit mit der im urbanen Umfeld üblichen hohen Objektanzahl zu ermöglichen, muss daher ein Mittel zur Datenreduktion gefunden werden, ohne die Fähigkeit zur flexiblen Konturdarstellung zu beeinträchtigen. Die Kontur wird hierzu durch einen einhüllenden Polygonzug approximiert, welcher durch eine beliebige Anzahl von Konturstützstellen definiert ist. Über die Starrkörper-Annahme herrscht ein fester Zusammenhang zwischen der Bewegung der einzelnen Stützstellen und dem eigentlichen Bewegungszentrum, welches dem Ursprung der lokalen Kartendarstellung entspricht. Aufbauend auf dieser Darstellung lassen sich alle relevanten Objektdaten in folgender Definition zusammenfassen:

Definition 6.1 (Objekt) *Ein Objekt besteht aus*

- den N_p Polygon-Stützstellen \mathbf{p}_i der lokalen Kartendarstellung,
- dem Zustandsvektor $\mathbf{x} = \begin{bmatrix} x_c & y_c & v & \phi & a & \dot{\phi} \end{bmatrix}^T$ und
- der Schätzfehler-Kovarianzmatrix \mathbf{P} .

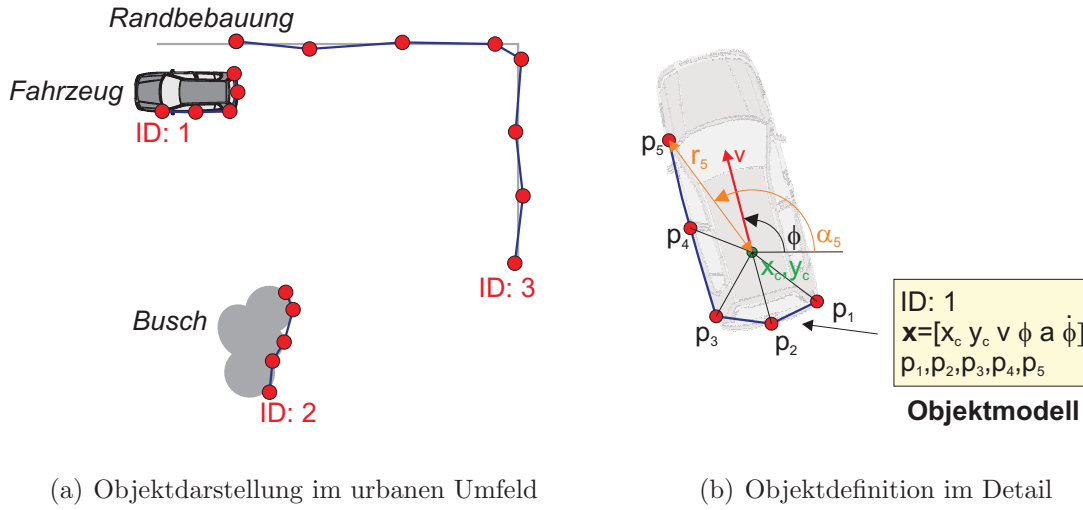


Abb. 6.2: Objektmodell auf Basis lokaler Karten

Hierbei ist x_c und y_c die Position des Bewegungszentrums auf der Fahrbahnoberfläche, v die Objektgeschwindigkeit, ϕ der Kurswinkel, a die Objektbeschleunigung und $\dot{\phi}$ die Kurswinkelgeschwindigkeit. Zwischen der Position der Kontur-Stützstellen \mathbf{p}_i und dem Bewegungszentrum des Objekts herrscht folgender Zusammenhang:

$$\mathbf{p}_i = \begin{pmatrix} x_i \\ y_i \end{pmatrix} = \begin{pmatrix} x_c \\ y_c \end{pmatrix} + \begin{pmatrix} r_i \cdot \cos(\phi + \alpha_i) \\ r_i \cdot \sin(\phi + \alpha_i) \end{pmatrix}. \quad (6.1)$$

Die Objekthöhe wird vernachlässigt, da keines der eingesetzten objektgebenden Sensorsysteme hierauf Rückschlüsse zulässt. Es ist als Besonderheit festzustellen, dass die Objektbeschreibung direkt in dem in Anhang A definierten, erdfesten Weltkoordinatensystem erfolgt. Dies leitet sich aus der in Kapitel 4 beschriebenen Fahrzeugarchitektur ab, bei der alle Umfelddaten in der einheitlich-erdfesten Koordinatendarstellung ausgedrückt werden.

Es gilt im Folgenden, die zeitliche Veränderung des Zustandsvektors sowie den Zusammenhang zwischen Zustands- und Messvektor mathematisch zu beschreiben.

6.1.1 Dynamikmodell

Für die Beschreibung der Objektdynamik soll auf die Kinematik realer, radgeführter Fahrzeuge zurückgegriffen werden. Gemäß des stationären Einspurmodells [91] führt die Fahrt bei konstantem Lenkwinkel zu einer Bewegung entlang der Kreisbahn mit Radius r , welcher

sich als Quotient aus Fahrgeschwindigkeit v und Kurswinkelgeschwindigkeit $\dot{\phi}$ ergibt.

$$r = \frac{v}{\dot{\phi}} \quad (6.2)$$

Die in Definition 6.1 zusätzlich eingeführte Beschleunigung a ermöglicht ferner eine zeitliche Änderung der Objektgeschwindigkeit. Durch die Modellierung auf Basis des linearen Einspurmodells sind Quer- und Längsbewegung des Objekts über den Kurswinkel ϕ bzw. die Kurswinkelgeschwindigkeit $\dot{\phi}$ verkoppelt, wodurch sich eine realistischere Modellierung des realen Bewegungsverhaltens dynamischer Objekte im allgemeinen Straßenverkehr ergibt als in vergleichbaren Implementierungen mit linear entkoppelten Bewegungsgleichungen (vgl. [12]).

Für die Herleitung der Bewegungsgleichung wird in Abb. 6.3 die inkrementelle Änderung des Zustandsvektors \mathbf{x} über der Zeitspanne Δt betrachtet. Näherungsweise werde davon ausge-




Abb. 6.3: Koordinierte Kreisfahrt mit konstanter Kurswinkelgeschwindigkeit

gangen, dass die Kurswinkelgeschwindigkeit über die betrachtete Zeitspanne hinweg konstant ist und eine gleichförmige Geschwindigkeit mit dem Betrag

$$\tilde{v}_k = v_k + \frac{1}{2} a_k \cdot \Delta t \quad (6.3)$$

$$\begin{aligned}
\Delta x &= dx_2 - dx_1 \\
&= r \cdot (\sin \phi_2 - \sin \phi_1) \\
&= \frac{\tilde{v}}{\dot{\phi}} \cdot (\sin(\phi + \Delta\phi) - \sin \phi) \quad \text{und} \\
\Delta y &= dy_2 - dy_1 \\
&= (r - r \cdot \cos \phi_2) - (r - r \cdot \cos \phi_1) \\
&= \frac{\tilde{v}}{\dot{\phi}} \cdot (\cos \phi - \cos(\phi + \Delta\phi)), \quad \text{mit} \\
\Delta\phi &= \dot{\phi} \cdot \Delta t.
\end{aligned} \tag{6.4}$$

Diagram illustrating the geometric interpretation of the rotation matrix $R_i(t)$. The diagram shows a coordinate system (x, y) at time $t = t + \Delta t$. A point (Schwerpunkt) is shown in two positions: its initial position (black dot) and its final position (red dot). The displacement vector is labeled r_i . The angle of rotation is labeled $\Delta\varphi$. The angle between the displacement vector and the x-axis is labeled α_i . The points are labeled Konturpunkt 1 and Konturpunkt 2.

aufgrund der Drehbewegung

$$\begin{aligned}\Delta x_i &= r_i \cdot (\cos(\alpha_i + \Delta\phi) - \cos \alpha_i) \quad \text{und} \\ \Delta y_i &= r_i \cdot (\sin(\alpha_i + \Delta\phi) - \sin \alpha_i), \quad \text{mit} \\ r_i &= \left| \begin{pmatrix} x_i \\ y_i \end{pmatrix} - \begin{pmatrix} x_c \\ y_c \end{pmatrix} \right| \quad \text{und} \\ \alpha_i &= \arctan \left(\frac{y_i - y_c}{x_i - x_c} \right).\end{aligned}\tag{6.5}$$

Auf Basis von Gleichung (6.4) und (6.5) ergibt sich das Prozessmodell für die zeitliche Änderung des Zustandsvektors zu

$$\begin{aligned}
\mathbf{x}_{k+1} &= \mathbf{f}(\mathbf{x}_k) \Rightarrow \\
x_{c_{k+1}} &= x_{c_k} + \frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k} \cdot \left(\sin(\phi_k + \dot{\phi}_k \cdot \Delta t) - \sin \phi_k \right), \\
y_{c_{k+1}} &= y_{c_k} + \frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k} \cdot \left(\cos \phi_k - \cos(\phi_k + \dot{\phi}_k \cdot \Delta t) \right), \\
v_{k+1} &= v_k + a \cdot \delta t, \\
\phi_{k+1} &= \phi_k + \dot{\phi}_k \cdot \Delta t, \\
a_{k+1} &= a_k \quad \text{und} \\
\dot{\phi}_{k+1} &= \dot{\phi}_k.
\end{aligned} \tag{6.6}$$

Die geänderte Position der einzelnen Stützstellen errechnet sich durch

$$\begin{aligned}
x_{i_{k+1}} &= x_{i_k} + \frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k} \cdot \left(\sin(\phi_k + \dot{\phi}_k \cdot \Delta t) - \sin \phi_k \right) + \\
&\quad r_{i_k} \cdot \left(\cos(\alpha_{i_k} + \dot{\phi}_k \cdot \Delta t) - \cos \alpha_{i_k} \right) \quad \text{und} \\
y_{i_{k+1}} &= y_{i_k} + \frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k} \cdot \left(\cos \phi_k - \cos(\phi_k + \dot{\phi}_k \cdot \Delta t) \right) + \\
&\quad r_{i_k} \cdot \left(\sin(\alpha_{i_k} + \dot{\phi}_k \cdot \Delta t) - \sin \alpha_{i_k} \right).
\end{aligned} \tag{6.7}$$

Bei der Implementierung müssen Vorkehrungen für $\dot{\phi} \approx 0$ getroffen werden. Es wird in diesem Fall der Grenzwert von Gleichung (6.4) gebildet, weiterhin verschwindet die Drehung der Konturpunkte. Es gilt in diesem Fall sowohl für die N_p Kontur-Stützstellen \mathbf{p}_i als auch für das Bewegungszentrum:

$$\begin{aligned}
x_{i/c_{k+1}} &= x_{i/c_k} + (v_k + \frac{1}{2}a_k \cdot \Delta t) \cdot \cos \phi \cdot \Delta t \quad \text{und} \\
y_{i/c_{k+1}} &= y_{i/c_k} + (v_k + \frac{1}{2}a_k \cdot \Delta t) \cdot \sin \phi \cdot \Delta t.
\end{aligned} \tag{6.8}$$

6.1.2 Systemrauschen

Jede Modellbildung bringt Vereinfachungen mit sich (hier z.B. die zeitlich konstante Beschleunigung und Gierrate), welche durch ein zusätzliches Systemrauschen bei der Zustands-

schätzung pauschal berücksichtigt werden müssen [6]. Im vorliegenden Fall wird von einem weißen, normalverteilten Rauschterm \mathbf{w} ausgegangen, wobei ein direkter Durchgriff auf die höchsten Ableitungen des Zustandsvektors angenommen wird. Man erhält

$$\mathbf{w} = \begin{bmatrix} w_a & w_{\dot{\phi}} \end{bmatrix}^T \quad (6.9)$$

mit der zugehörigen Kovarianzmatrix \mathbf{W} . Darauf aufbauend ergibt sich die für den Einsatz des Kalmanfilters notwendige Kovarianzmatrix des Prozessrauschens zu

$$\begin{aligned} \mathbf{Q} &= \mathbf{\Gamma} \cdot \mathbf{W} \cdot \mathbf{\Gamma}^T, \quad \text{mit} \\ \mathbf{\Gamma} &= \frac{\partial \mathbf{f}(\mathbf{x})}{\partial (a, \dot{\phi})}. \end{aligned} \quad (6.10)$$

6.1.3 Eingangsdaten und Messrauschen

Für eine Betrachtung des mathematischen Zusammenhanges zwischen Mess- und Zustandsvektor bzw. die Berücksichtigung der damit verbundenen Unsicherheiten müssen die Charakteristika der eingesetzten Sensortypen analysiert werden. Diese stellen im vorliegenden Fall aufgrund ihrer Messprinzipien eine unterschiedliche Eingangsdatenbasis zur Verfügung (Abb. 6.5):

- Die Laserscanner liefern für jedes erfasste Objekt einen komplexen Polygonzug, bestehend aus mehreren Messpunkten p_1 bis p_i (vgl. Abb. 6.5a).
- Die Multibeam Lidar-Sensoren erzeugen für jedes Objekt eine Positions- und Breitenangabe, die sich in eine Darstellung mit linkem und rechtem Messpunkt überführen lässt (vgl. Abb. 6.5b).
- Die Radarsensoren übermitteln die Position des Reflexions-Maximums als einziger Messpunkt auf dem Objekt (vgl. Abb. 6.5c).

Alle Sensoren erzeugen aufgrund der sensorinternen Datenvorverarbeitung einen Ausgabe- wert für die Objektgeschwindigkeit. Da diese lediglich durch den Radarsensor direkt gemessen werden kann, wird der Geschwindigkeitsschätzwert der LIDAR-Sensoren aufgrund der geringen Güte für das Objekttracking nicht berücksichtigt.

Es wird davon ausgegangen, dass die Messpunkte der Sensoren direkt mit den Stützstellen der lokalen Kartendarstellung korrelieren. Betrachtet man unabhängig von der Art der Zuordnung das zugrunde liegende Messprinzip, so liegt allen Sensoren eine Abstands- und Winkelmessung zugrunde. Dieses Messprinzip ist Ausgangspunkt für die Modellierung des

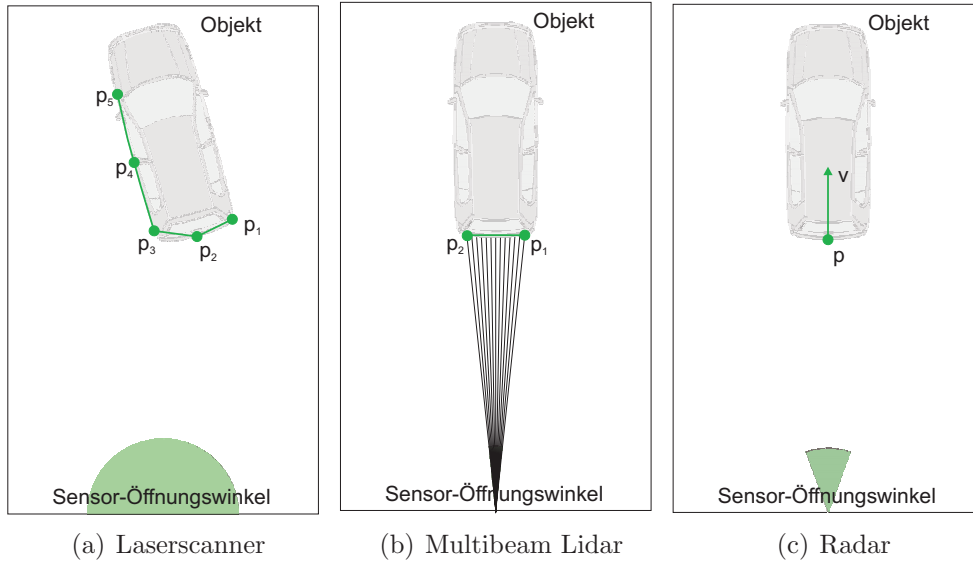


Abb. 6.5: Sensordaten der objektgebenden Umfeldsensorik

Messrauschens. Im Folgenden soll von einem einzelnen Messpunkt ausgegangen werden. Das Sensorsystem erzeugt für diesen Fall einen Messvektor \mathbf{r} dessen Unsicherheiten durch die Kovarianzmatrix des Messrauschens \mathbf{R} ausgedrückt werden. Es gilt

$$\mathbf{r} = \begin{pmatrix} r \\ \alpha \end{pmatrix} \quad \text{und} \quad \mathbf{R} = E[\mathbf{r} \cdot \mathbf{r}^T] = \begin{bmatrix} \sigma_r^2 & 0 \\ 0 & \sigma_\alpha^2 \end{bmatrix}. \quad (6.11)$$

Hierbei ist r der Abstand zwischen Sensor und Zielobjekt und α der Erfassungswinkel des Ziels in Bezug auf das Sensorkoordinatensystem (vgl. Abschnitt A). Als Messrauschen wird ein normalverteilter Rauschprozess mit der Standardabweichung σ_r bzw. σ_α angenommen. Die Parameter σ_r und σ_α werden konservativ auf Basis der Hersteller-Angaben (Datenblatt) abgeschätzt. Um der in Kapitel 4 beschriebenen einheitlichen Darstellung aller Umfelddaten in einem erdfesten Bezugssystem gerecht zu werden, muss eine Transformation der Messunsicherheiten erfolgen. Diese lässt sich in drei Teilschritte unterteilen:

- Zunächst erfolgt eine Transformation von der polaren Darstellung \mathbf{R} in eine äquivalente Darstellung \mathbf{R}_S ausgedrückt in kartesischen Koordinaten.

$$\mathbf{R}_S = \begin{bmatrix} \cos \alpha & -r \cdot \sin \alpha \\ \sin \alpha & r \cdot \cos \alpha \end{bmatrix} \cdot \begin{bmatrix} \sigma_r & 0 \\ 0 & \sigma_\alpha \end{bmatrix} \cdot \begin{bmatrix} \cos \alpha & -r \cdot \sin \alpha \\ \sin \alpha & r \cdot \cos \alpha \end{bmatrix}^T. \quad (6.12)$$

Der Transformation liegt eine Linearisierung der nichtlinearen Abbildungsvorschrift von Polarkoordinaten in kartesische Koordinaten zugrunde. Der Linearisierungsfehler wird analog zur Vorgehensweise beim erweiterten Kalmanfilter vernachlässigt.

- In einem Zwischenschritt erfolgt die Überführung der lokalen Sensorkoordinatensysteme in ein einheitliches fahrzeugfestes Bezugssystem. Der Zusammenhang ist gemäß Anhang A über die Kalibriermatrix \mathbf{T}_{SF} der Sensoren gegeben, so dass sich für das Messrauschen \mathbf{R}_F im fahrzeugfesten Bezugssystem folgender Zusammenhang ergibt:

$$\mathbf{R}_F = \mathbf{T}_{SF} \cdot \mathbf{R}_S \cdot \mathbf{T}_{SF}^T. \quad (6.13)$$

Die Transformation ist linear und zeitinvariant, so dass keine zusätzlichen Fehlereinflüsse durch die Abbildung entstehen.

- Der letzte Teilschritt berücksichtigt die Transformation der Messdaten vom fahrzeugfesten in das erdfeste Bezugssystem. Der in die Transformation eingehende Fahrzeug-Zustandsvektor ist selbst eine unsicherheitsbehaftete Messgröße. Diese zusätzliche Unsicherheit muss dem Messrauschen zugeschlagen werden. Man erweitert dazu den Messvektor um den Fahrzeug-Zustandsvektor \mathbf{y}_{ego} . Es gilt

$$\mathbf{y}_{ego} = \begin{bmatrix} \Psi_{ego} & x_{ego} & y_{ego} \end{bmatrix}^T, \quad (6.14)$$

$$\mathbf{y}_{erw} = \begin{bmatrix} \mathbf{y}_F & \mathbf{y}_{ego} \end{bmatrix}^T \quad \text{und} \quad (6.15)$$

$$\mathbf{R}_{erw} = \begin{bmatrix} \mathbf{R}_F & \mathbf{0} \\ \mathbf{0} & \mathbf{R}_{ego} \end{bmatrix}. \quad (6.16)$$

Hierbei ist Ψ_{ego} der Kurswinkel des Fahrzeugs und (x_{ego}, y_{ego}) ist die Position des Fahrzeugs bezüglich des erdfesten Koordinatensystems. Die Unsicherheit des Fahrzeug-Zustandsvektors \mathbf{R}_{ego} , mit

$$\mathbf{R}_{ego} = \begin{bmatrix} \sigma_{\Psi_{ego}}^2 & 0 & 0 \\ 0 & \sigma_{x_{ego}}^2 & 0 \\ 0 & 0 & \sigma_{y_{ego}}^2 \end{bmatrix}, \quad (6.17)$$

kann von der Ortungsplattform abgerufen werden. Im Folgenden gilt $s = \sin \Psi_{ego}$ und $c = \cos \Psi_{ego}$. Man erhält für den Messvektor in erdfesten Koordinaten

$$\mathbf{y}_W = \begin{bmatrix} c & -s \\ s & c \end{bmatrix} \cdot \mathbf{y}_F + \begin{pmatrix} x_{ego} \\ y_{ego} \end{pmatrix}. \quad (6.18)$$

Durch Linearisierung um \mathbf{y}_{erw} ergibt sich die Transformationsmatrix \mathbf{T}_{WF} für das Messrauschen zu:

$$\mathbf{T}_{WF} = \begin{bmatrix} c & -s & -s \cdot x^f - c \cdot y^f & 1 & 0 \\ s & c & c \cdot x^f - s \cdot y^f & 0 & 1 \end{bmatrix}. \quad (6.19)$$

Für das transformierte Messrauschen der Sensoren, ausgedrückt im Weltkoordinatensystem erhält man:

$$\mathbf{R}_W = \mathbf{T}_{WF} \cdot \mathbf{R}_{erw} \cdot \mathbf{T}_{WF}^T. \quad (6.20)$$

Eine analoge Berechnung kann für die Unsicherheit der Geschwindigkeitsmesswerte der verwendeten Radarsensoren angestellt werden, wobei die zusätzliche Scheinbewegung auf Basis der Fahrzeug-Gierbewegung zu berücksichtigen ist (siehe Abschnitt A.2.4).

6.2 Aufbau der Tracking-Algorithmen

Um den Einsatz in der komplexen urbanen Fahrzeugumgebung zu ermöglichen sowie die Eigenheiten des um die lokale Kartendarstellung erweiterten Objektmodells zu berücksichtigen, sind einige Modifikationen des klassischen Tracking-Konzeptes (vgl. Abbildung 5.10) notwendig.

- Die Datenzuordnung wird in zwei Stufen aufgeteilt. Im ersten Teilschritt (Stufe-1-Assoziation) erfolgt die Zuweisung eingehender Messdaten zu den Objektdaten des Umfeldmodells unter Berücksichtigung der Kontur-Ähnlichkeit. Hierbei wird der Abstand der eingehenden Messpunkte von den Polygon-Segmenten der Objektdarstellung sowie der Grad der Überdeckung bewertet. Ist die Kontur-Ähnlichkeit für eine Zuordnung nicht ausreichend, so werden die Messdaten in die Trackinitialisierung überführt, andernfalls wird mit dem zweiten Teilschritt (Stufe-2-Assoziation) fortgefahren. Ziel der zweiten Stufe ist eine Bestimmung des direkten Zusammenhanges zwischen den Messpunkten und den Stützstellen der Objektkontur. Es gilt, nach Möglichkeit für jede Stützstelle der Objektkontur den korrespondierenden Messpunkt zu ermitteln. Verbleiben am Ende der Feinassoziation Messpunkte ohne Zuordnungspartner, so werden diese als Kandidat für eine spätere Konturerweiterung gekennzeichnet. Der Vorgang ist in Abb. 6.6a und 6.6b dargestellt.

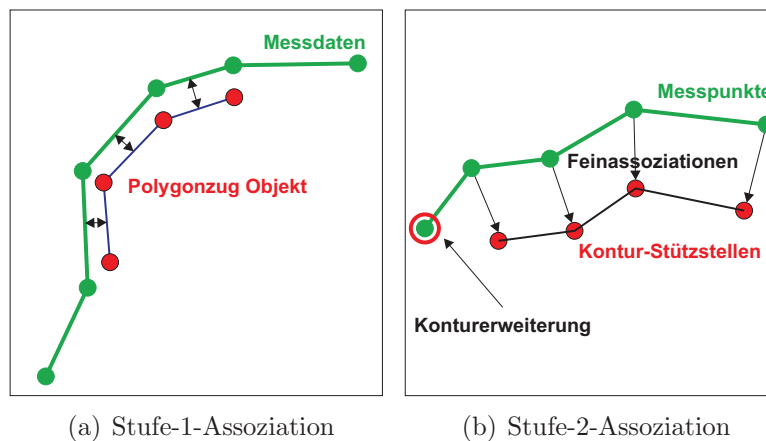


Abb. 6.6: Prinzip der Datenassoziation

- Die Trackinitialisierung wird erweitert um einen vereinfachten Tracking-Algorithmus (Pretracking), welcher eine zeitliche Verfolgung eingehender Messdaten sowie eine Plausibilisierung über mehrere Sensorsysteme hinweg ermöglicht. Zusätzlich erfolgt ein Abgleich mit der in Kapitel 7 beschriebenen Fahrbereichsanalyse, um unerwünschte Bodenreflexionen der LIDAR-Sensorik zu unterdrücken.
- Die Trackverwaltung wird ergänzt um eine Konturverwaltung der einzelnen Objekte. Diese ermöglicht eine Erweiterung der Objektkontur, falls durch eine geänderte Perspektive neue Objektmerkmale durch die Sensorik geliefert bzw. eine Bereinigung der Objektkontur, falls Stützstellen wiederholt nicht durch die Sensorik bestätigt werden.

Für die Verarbeitung und Fusion der asynchron eintreffenden Messdaten wird das in Abschnitt 5.4.1 eingeführte Prinzip der Messwertpufferung angewendet. Um einen effizienten Zugriff auf das Umfeldmodell zu ermöglichen, wurde zusätzlich eine optimierte Echtzeit-Datenbank realisiert [99]. Es ergibt sich der in Abb. 6.7 dargestellte zweikreisige Datenfluss.

6.3 Datenassoziation

In beiden Stufen der Datenzuordnung wird das in Abschnitt 5.2.6 eingeführte Prinzip der Einfachzuordnung angewendet. Zunächst gilt es, für jede mögliche Kombination zwischen den im Umfeldmodell vorhandenen Objekten und den vom Sensorsystem eingehenden Messvektoren ein skalares Gütemaß zu bestimmen, welches als Entscheidungskriterium für die Einfachzuordnung herangezogen werden kann. Durch die lokale Kartendarstellung der Ob-

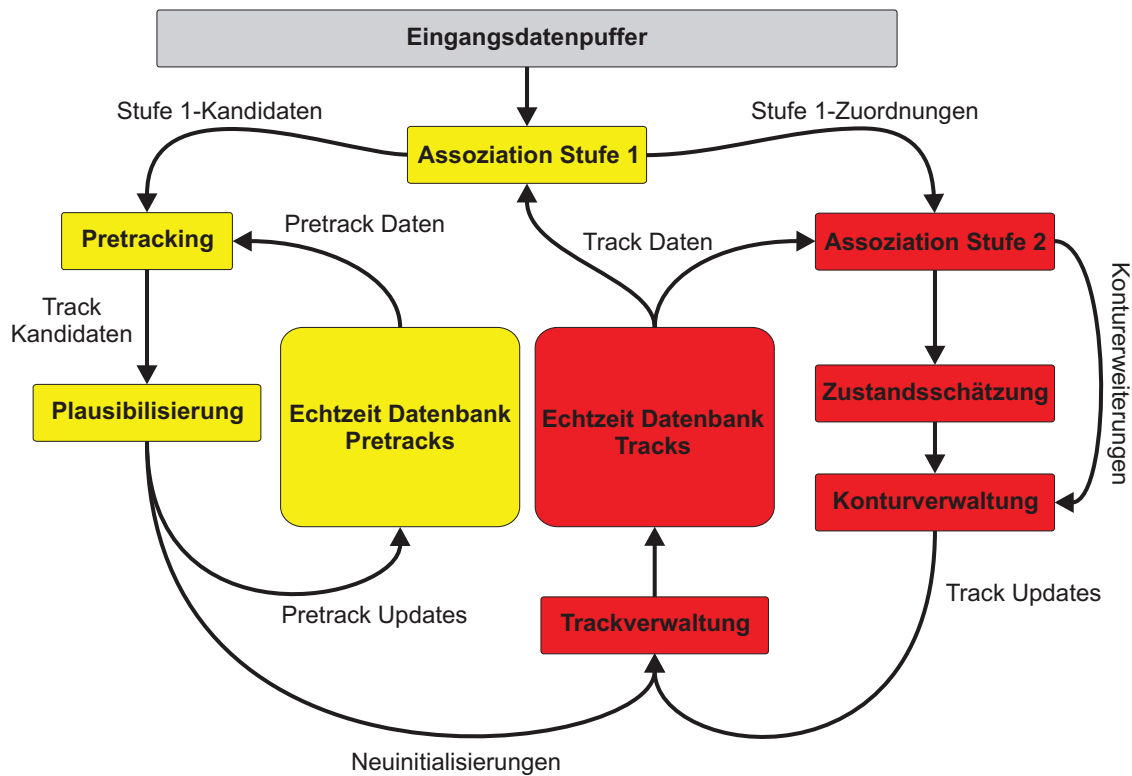


Abb. 6.7: Architektur der urbanen Objektverfolgung

jekte muss dieses Gütemaß dabei auf eine Berücksichtigung der Konturverläufe erweitert werden.

6.3.1 Stufe-1-Assoziation

Im Rahmen der Stufe-1-Assoziation gilt es daher, drei verschiedene Assoziationsfälle zu unterscheiden (vgl. Abb. 6.6a):

- Punkt-zu-Punkt-Assoziation:

Besteht sowohl das Objekt als auch der Messvektor lediglich aus einem einzelnen Kontur- bzw. Messpunkt, so kann ein simpler Vergleich der Positionswerte (x, y) erfolgen. Das skalare Gütemaß $d_1(i, j)$ von Objekt i und Messung j ergibt sich in diesem Fall zu

$$d_1(i, j) = \begin{cases} \frac{(x_j - x_i)^2}{a^2} + \frac{(y_j - y_i)^2}{b^2} & \text{falls } \frac{(x_j - x_i)^2}{a^2} + \frac{(y_j - y_i)^2}{b^2} \leq d_{1_{max}} \quad \text{und} \\ -1 & \text{sonst.} \end{cases} \quad (6.21)$$

Die Parameter a und b bestimmen die Ausdehnung der für die Zuordnung herangezogenen Konfidenzellipse (vgl. Kapitel 5.2.6, Abb. 5.11) und leiten sich aus der Hauptdiagonalen der Innovationskovarianz zwischen Messung und Objektzustand ab (3-fache Standardabweichung). Die Schwellwertüberprüfung mit $d_{1_{max}}$ entspricht einer Messwertvalidierung zur Unterdrückung unplausibler Zuordnungen.

- Punkt-zu-Linie-Assoziation:

Besteht entweder der Messvektor oder die Objektdarstellung aus einem mehrelementigen Polygonzug, so erfolgt ein abschnittsweiser Punkt-zu-Linie Vergleich zur Bestimmung des Gütemaßes. Es sei im Folgenden $(x_{i,k}, y_{i,k})$ die k -te Kontur-Stützstelle des Objekts und (x_j, y_j) der vom Sensor übermittelte Messpunkt. Man berechnet zunächst die Lotfußpunkte $(l_{x,k}, l_{y,k})$ des Messpunkts auf die Objektkontur zu

$$\begin{aligned} l_{x,k} &= x_{i,k} + \lambda \cdot (x_{i,k+1} - x_{i,k}) \quad \text{und} \\ l_{y,k} &= y_{i,k} + \lambda \cdot (y_{i,k+1} - y_{i,k}), \quad \text{mit} \\ \lambda &= \frac{(x_j - x_{i,k})(x_{i,k+1} - x_{i,k}) + (y_j - y_{i,k})(y_{i,k+1} - y_{i,k})}{(x_{i,k+1} - x_{i,k})^2 + (y_{i,k+1} - y_{i,k})^2}. \end{aligned} \quad (6.22)$$

Eine Beschränkung auf $0 \leq \lambda \leq 1$ begrenzt das zulässige Intervall auf den durch die Stützstellen k und $k+1$ definierten Linienzug. Man erhält

$$d_{1_{min}} = \min_k \left(\frac{(x_j - l_{x,k})^2}{a^2} + \frac{(y_j - l_{y,k})^2}{b^2} \right) \quad (6.23)$$

und schließlich die Zuordnungskosten $d_1(i, j)$ zu

$$d_1(i, j) = \begin{cases} d_{1_{min}} & \text{falls } d_{1_{min}} \leq d_{1_{max}} \quad \text{und} \\ -1 & \text{sonst.} \end{cases} \quad (6.24)$$

Durch den Minimum-Operator in Gleichung (6.23) wird jeweils die günstigste Paarung zurückgegeben. Die Berechnung erfolgt analog im umgekehrten Fall (mehrelementiger Messvektor, punktförmiges Objekt).

- Linie-zu-Linie-Assoziation:

Im häufigsten Fall bestehen beide Zuordnungspartner aus einem mehrelementigen Konturzug. In diesem Fall wird der Punkt-zu-Linie Vergleich sequentiell für alle Messpunkte ausgeführt. Auf Basis von Gleichung (6.24) ergibt sich für jeden Messpunkt l der Güte wert $d_{1,l}(i, j)$. Um den Grad der Überdeckung zwischen Messung und Objektdarstellung zu bewerten, sichert man für jedes Teilsegment das Ergebnis der Messwertvalidierung

separat im Validierungsereignis Θ_l , mit

$$\Theta_l = \begin{cases} 1 & \text{falls } d_{1,l}(i, j) \geq 0 \quad \text{und} \\ 0 & \text{sonst.} \end{cases} \quad (6.25)$$

Die Validierungsereignisse werden in den binären Ausdruck B überführt, mit

$$B = \begin{cases} 1 & \text{falls } \sum_{l=1}^{M_p} \Theta_l \geq N_p \cdot p_1 \quad \text{oder} \quad \sum_{l=1}^{M_p} \Theta_l \geq M_p \cdot p_2 \quad \text{und} \\ 0 & \text{sonst.} \end{cases} \quad (6.26)$$

Die Werte p_1 und p_2 mit $0 \leq p_{1,2} \leq 1$ sind Schwellwerte, um die Anzahl der kompatiblen Konturpunkte zwischen Mess- und Zustandsvektor zu gewichten, die Werte N_p bzw. M_p sind die Anzahl der Kontur-Stützstellen in der Objektdarstellung bzw. die Messpunkte. Um eine einzelne skalare Größe als Gütewert für die Zuordnung zu erhalten, bildet man den Mittelwert über alle $d_{1,l}(i, j)$, die innerhalb der Validierungsregion liegen. Man erhält

$$d_{1_{mean}}(i, j) = \frac{1}{\sum_{l=1}^{M_p} \Theta_l} \sum_{l=1}^{M_p} \Theta_l \cdot d_{1,l}(i, j) \quad (6.27)$$

Das Gesamtergebnis für die Gütefunktion ergibt sich zu

$$d_1(i, j) = \begin{cases} d_{1_{mean}}(i, j) & \text{falls } B \equiv 1 \quad \text{und} \\ -1 & \text{sonst.} \end{cases} \quad (6.28)$$

Für die Anwendung des Optimierungsalgorithmus werden die Gütewerte $d_1(i, j)$ für alle Kombinationsmöglichkeiten in der Kostenmatrix \mathbf{D}_1 zusammengeführt. Es gilt

$$\mathbf{D}_1 = \begin{bmatrix} d_1(1, 1) & \dots & d_1(1, M) \\ & \dots & \\ d_1(N, 1) & \dots & d_1(N, M) \end{bmatrix}. \quad (6.29)$$

Hierbei ist N die Gesamtanzahl aller Objekte (Tracks) im Umfeldmodell und M die Menge der Messvektoren (Messobjekte), die in der aktuellen Zeitscheibe durch eines der Sensorsysteme geliefert wurden.

6.3.2 Stufe-2-Assoziation

Die erste Stufe der Datenassoziation löst nur die Fragestellung der Zugehörigkeit zwischen den von den Sensoren gelieferten Messungen und den Objekten des Umfeldmodells auf, nicht aber die exakte Zugehörigkeit der Messpunkte zu den Kontur-Stützstellen der Objektdarstellung. Aufgrund der Ähnlichkeit dieser beiden Aufgabenstellungen kann jedoch ein gleichartiges Zuordnungsschema angewendet werden, wobei als Zuordnungspartner nicht weiter die Objekt- und Messdaten selbst, sondern die darin enthaltenen Kontur- und Messpunkte herangezogen werden. Der Gütewert $d_2(k, l)$ für die Ähnlichkeit der Kontur-Stützstelle k zum Messpunkt l einer zuvor getroffenen Stufe-1-Assoziation wird berechnet durch

$$d_2(k, l) = \begin{cases} \frac{(x_{i,k}-x_{j,l})^2}{a^2} + \frac{(y_{i,k}-y_{j,l})^2}{b^2} & \text{falls } \frac{(x_{i,k}-x_{j,l})^2}{a^2} + \frac{(y_{i,k}-y_{j,l})^2}{b^2} \leq d_{2_{max}}. \\ -1 & \text{sonst.} \end{cases} \quad \text{und} \quad (6.30)$$

Um für diese Feinassoziation eine engere Bindung der Stützstellen zu fordern als bei der Stufe-1-Assoziation, gilt $d_{2_{max}} < d_{1_{max}}$. Eine Berechnung von $d_2(k, l)$ über alle Kombinationsmöglichkeiten führt zur Kostenmatrix \mathbf{D}_2 , mit

$$\mathbf{D}_2 = \begin{bmatrix} d_2(1, 1) & \dots & d_2(1, M_p) \\ & \dots & \\ d_2(N_p, 1) & \dots & d_2(N_p, M_p) \end{bmatrix}. \quad (6.31)$$

Hierbei sind N_p und M_p die Anzahl der Kontur-Stützstellen im Zustands- bzw. Messvektor.

6.3.3 Optimierungsalgorithmus

Durch die Erstellung der Kostenmatrizen \mathbf{D}_1 und \mathbf{D}_2 lässt sich das Bestimmen einer optimalen Zuordnung auf folgende Problemstellung zurückführen: Wähle in jeder Zeile von \mathbf{D} genau ein nichtnegatives Element $d(i, j)$ aus, so dass die Summe aller gewählten Elemente minimal wird. Zur Lösung dieser Aufgabe stehen eine Reihe verschiedener Algorithmen zur Verfügung, wobei hier der in [108] eingeführte Minimum-Filter (Extended Nearest Neighbour Algorithmus) zum Einsatz kommt.

Zunächst wird zeilenweise das jeweils kleinste noch nicht zugeordnete Element der Kostenmatrix als Kandidat markiert und anschließend spaltenweise der kleinste Kandidat in jeder Spalte zugeordnet. Nach einer erfolgten Zuordnung wird die Kostenmatrix entsprechend verkleinert und der Ablauf von Neuem gestartet. Der Algorithmus 6.1 kann unverändert für die Optimierung beider Kostenmatrizen eingesetzt werden.

Algorithmus 6.1 Minimum-Filter

```

1: for Zeile = 1 to N do
2:   for Spalte = 1 to M do
3:     Markiere das kleinste nichtnegative Element in der aktuellen Zeile als Kandidat für
       die Zuordnung, wenn weder dessen Zeile noch Spalte bereits bedeckt wurden.
4:   end for
5: end for
6: for Spalte = 1 to M do
7:   for Zeile = 0 to N do
8:     Suche den kleinsten Kandidaten in der aktuellen Spalte.
9:     if Kleinster Kandidat vorhanden then
10:      Sichere die Zuordnung in der Zuordnungsmatrix  $\Theta$ .
11:      Bedecke die Zeile der Zuordnung.
12:      Bedecke die Spalte der Zuordnung.
13:      Entferne alle Kandidaten-Markierungen.
14:      Gehe zurück zu Zeile 1:
15:    end if
16:  end for
17:  Fahre mit der nächsten Spalte fort.
18: end for
19: Wenn die letzte Spalte erreicht wurde, gebe die Zuordnungsmatrix  $\Theta$  zurück.
20: return

```

Es resultiert die Zuordnungsmatrix Θ , mit

$$\Theta = \begin{bmatrix} \Theta(1,1) & \dots & \Theta(1,M) \\ & \dots & \\ \Theta(N,1) & \dots & \Theta(N,M) \end{bmatrix}. \quad (6.32)$$

Es gilt hierbei

$$\sum_{i=1}^N \Theta(i,j) \leq 1 \quad \forall j \quad \text{und} \\ \sum_{j=1}^N \Theta(i,j) \leq 1 \quad \forall i.$$

Das Minimum-Filter liefert nicht in allen Fällen eine global optimale Zuordnung, ist aber bezüglich der Rechenzeit aufwendigeren Optimierungsalgorithmen überlegen [108]. Da unter Verwendung von Sensoren mit interner Objektbildung in der Praxis bereits die vorgelagerte Messwertvalidierung einen Großteil der möglichen Zuordnungen ausschließt (negative Elemente in \mathbf{D}), ergibt sich ein für die praktische Anwendung ausreichendes Gesamtergebnis.

6.4 Zustandsschätzung für das Freiform-Modell

Das in Abschnitt 6.1 hergeleitete Dynamikmodell für die Objektbewegung ist nichtlinear, so dass für die Zustandsschätzung das erweiterte Kalmanfilter herangezogen werden soll. Die Objektbeschreibung auf Basis der lokalen Kartendarstellung führt bei der Anwendung des Schätzalgorithmus zu der Herausforderung, dass durch das Sensorsystem nicht die Position des Bewegungszentrums (Schwerpunkt) eines Objektes messtechnisch direkt erfassbar ist, sondern lediglich die Position einer oder mehrerer Stützstellen auf der Objektkontur. Es gilt daher, von der Einzelbewegung der Kontur-Stützstellen auf die Gesamtbewegung des Objektes zu schließen. Eine intuitive Herangehensweise an diese Problematik ist die Erweiterung des Zustandsvektors um die Stützstellen der lokalen Kartendarstellung, wodurch sich folgende Darstellung ergibt:

$$\mathbf{x} = \begin{bmatrix} x_c & y_c & v & \phi & a & \dot{\phi} & r_1 & \alpha_1 & \dots & r_{N_p} & \alpha_{N_p} \end{bmatrix}^T. \quad (6.33)$$

Die Systemausgangsfunktion jedes einzelnen Konturpunktes ließe sich in diesem Fall zu

$$\begin{pmatrix} x_i \\ y_i \end{pmatrix} = \begin{pmatrix} x_c \\ y_c \end{pmatrix} + r_i \cdot \begin{pmatrix} \cos(\phi + \alpha_i) \\ \sin(\phi + \alpha_i) \end{pmatrix} \quad (6.34)$$

angeben, womit prinzipiell eine mathematische Herleitung der Filtergleichung möglich wäre. Bei einer praktischen Umsetzung ergeben sich allerdings eine Reihe von Einschränkungen:

- Die Aufnahme der Kontur-Stützstellen führt zu einer variablen Dimension des Zustandsvektors bzw. der relevanten Kovarianz- und Verstärkungsmatrizen des Kalmanfilters. Eine algorithmische Implementierung mit variablen Matrixdimensionen ist aufgrund der dafür notwendigen dynamischen Speicherverwaltung wenig effizient und verhindert die Echtzeitfähigkeit des Algorithmus in der komplexen urbanen Umgebung mit einer entsprechend hohen Anzahl gleichzeitig verfolgter Objekte.
- Da nicht zu jedem Zyklus eine Messung aller Stützstellen sichergestellt ist, ergeben sich Probleme hinsichtlich der Beobachtbarkeit (vgl. Abschnitt 5.2.1). Eine Unterdrückung der Schätzfilterkorrektur auf die betroffenen Stützstellen ist durch Nullsetzen der korrespondierenden Zeilen in der linearisierten Systemausgangsmatrix \mathbf{H} zwar möglich [114], ändert jedoch an der ursprünglichen Problematik nichts.
- Führt das Objekt neben einer Translationsbewegung auch eine Drehbewegung um das Bewegungszentrum aus, ergibt sich ferner eine Mehrdeutigkeit für die Rekonstruktion der Drehbewegung, welche im folgenden Abschnitt diskutiert wird.

6.4.1 Mehrdeutigkeit von Rotation und Translation

Auf Basis der Prädiktion des Zustandsvektors lässt sich für jede Kontur-Stützstelle \mathbf{p}_i die prädiizierte Position \mathbf{p}_i^* berechnen, an welcher der im Rahmen der Stufe-2-Assoziation bestimmte korrespondierende Messpunkt erwartet wird. Stimmt der Zustandsvektor des Objektes nicht exakt mit dessen realer Bewegung überein, ergeben sich Abweichungen, welche zur Korrektur des Objektzustandes herangezogen werden müssen (Innovation des Schätzfilters). Aufgrund des gewählten Bewegungsmodells lassen sich diese als affine Abbildung

$$\mathbf{p}_i = \mathbf{R} \cdot \mathbf{p}_i^* + \mathbf{t} \quad (6.35)$$

bestehend aus der unbekannten Rotation \mathbf{R} und Translation \mathbf{t} bezüglich des Bewegungszentrums ausdrücken. Es stellt sich hierbei jedoch heraus, dass sich für jede beliebige Lage des Drehzentrums eine entsprechende Translation \mathbf{t}_{k+1} finden lässt, die zu einer gültigen Lösung der Punkt-zu-Punkt-Korrespondenz führt, wie in Abb. 6.8 dargestellt ist. Die Lage




Abb. 6.8: Mehrdeutige Abbildung einer Punktwolke

des Drehzentrums ist nicht eindeutig bestimmbar, was sich bei Anwendung des erweiterten Kalmanfilters auf die Systembeschreibung aus Gleichung (6.33) und (6.34) durch

$$\text{Rang} \begin{bmatrix} \mathbf{H} \\ \mathbf{HF} \\ \mathbf{HF}^2 \\ \vdots \\ \mathbf{HF}^{n-1} \end{bmatrix} = N - 2, \quad (6.36)$$

ausdrückt.

6.4.2 Vereinfachte Filtergleichung

Um das Problem der Mehrdeutigkeit zu umgehen, soll eine vereinfachte Filtergleichung entwickelt werden. Beim Abgleich der prädizierten und messtechnisch erfassten Kontur-Stützstellen werde hierzu die unbekannte Rotation \mathbf{R} zunächst vernachlässigt und anstelle dessen die Translation \mathbf{t} bestimmt, welche den geringsten Abbildungsfehler gemäß Gleichung (6.35) verursacht. Diese ergibt sich als Least-Squares Approximation aus der Korrespondenz der betrachteten Stützstellen. Man definiert den Fehlerterm \mathbf{e} zu

$$\mathbf{e}_i = \mathbf{p}_i - \mathbf{p}_i^* - \mathbf{t} \quad (6.37)$$

und bildet die quadratische Fehlersumme über alle Korrespondenzen. Man erhält

$$\sum_{i=1}^{N_m} \frac{1}{2} \mathbf{e}^T \mathbf{e} = \frac{1}{2} \sum_{i=1}^{N_m} (\mathbf{p}_i - \mathbf{p}_i^*)^T (\mathbf{p}_i - \mathbf{p}_i^*) - (\mathbf{p}_i - \mathbf{p}_i^*)^T \cdot \mathbf{t} - \mathbf{t}^T \cdot (\mathbf{p}_i - \mathbf{p}_i^*) + \mathbf{t}^T \mathbf{t}. \quad (6.38)$$

Durch partielles Ableiten nach \mathbf{t} und Nullsetzen der Ableitung ergibt sich

$$0 = \frac{1}{2} \sum_{i=1}^{N_m} -2 (\mathbf{p}_i - \mathbf{p}_i^*) + 2\mathbf{t}. \quad (6.39)$$

Schließlich erhält man die gesuchte Translation \mathbf{t} zu

$$\mathbf{t} = \frac{1}{N_m} \sum_{i=1}^{N_m} (\mathbf{p}_i - \mathbf{p}_i^*). \quad (6.40)$$

Hierbei ist N_m die Anzahl der Punkt-Korrespondenzen am Ende der Stufe-2-Assoziation. Die Vereinfachung bewirkt in der Praxis, dass anstelle des nicht eindeutig bestimmmbaren Objekt-Schwerpunkts (x_c, y_c) der Centroid (x'_c, y'_c) der N_m assoziierten Kontur-Stützstellen als Bezugspunkt der Objektbewegung betrachtet wird. Dieser berechnet sich zu

$$\begin{pmatrix} x'_c \\ y'_c \end{pmatrix} = \frac{1}{N_m} \sum_{i=1}^{N_m} \mathbf{p}_i. \quad (6.41)$$

Für den Centroiden gelte das in Gleichung (6.6) angegebene Bewegungsmodell, so dass sich die Systemübergangsfunktion $\mathbf{f}(x'_c, y'_c, v, \phi, a, \omega)$ zu

$$\begin{aligned}
 x'_{c_{k+1}} &= x'_{c_k} + \frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k} \cdot \left(\sin(\phi_k + \dot{\phi}_k \cdot \Delta t) - \sin \phi_k \right) \\
 y'_{c_{k+1}} &= y'_{c_k} + \frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k} \cdot \left(\cos \phi_k - \cos(\phi_k + \dot{\phi}_k \cdot \Delta t) \right) \\
 v_{k+1} &= v_k + a \cdot \delta t \\
 \phi_{k+1} &= \phi_k + \dot{\phi}_k \cdot \Delta t \\
 a_{k+1} &= a_k \\
 \dot{\phi}_{k+1} &= \dot{\phi}_k,
 \end{aligned} \tag{6.42}$$

ergibt. Für die Anwendung des erweiterten Kalmanfilters erhält man die Jacobi-Matrix \mathbf{F}_k zu

$$\mathbf{F}_k = \left. \frac{\partial \mathbf{f}(\mathbf{x})}{\partial (x'_c, y'_c, v, \phi, a, \dot{\phi})} \right|_{\mathbf{x}=\mathbf{x}_k} = \begin{bmatrix} f_{1,1} & \dots & f_{1,6} \\ & \dots & \\ f_{6,1} & \dots & f_{6,6} \end{bmatrix}. \tag{6.43}$$

Es gilt hierbei

$$\begin{aligned}
f_{1,1} &= 1, \\
f_{1,2} &= 0, \\
f_{1,3} &= \frac{1}{\dot{\phi}_k} \cdot \left(\sin(\phi_k + \dot{\phi}_k \cdot \Delta t) - \sin \phi_k \right), \\
f_{1,4} &= \frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k} \cdot \left(\cos(\phi_k + \dot{\phi}_k \cdot \Delta t) - \cos \phi_k \right), \\
f_{1,5} &= \frac{\Delta t}{2\dot{\phi}_k} \cdot \left(\sin(\phi_k + \dot{\phi}_k \cdot \Delta t) - \sin \phi_k \right), \\
f_{1,6} &= -\frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k^2} \cdot \left(\sin(\phi_k + \dot{\phi}_k \cdot \Delta t) - \sin \phi_k \right) + \\
&\quad \frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k} \cdot \left(\cos(\phi_k + \dot{\phi}_k \cdot \Delta t) \Delta t \right), \\
f_{2,1} &= 0, \\
f_{2,2} &= 1, \\
f_{2,3} &= \frac{1}{\dot{\phi}_k} \cdot \left(\cos \phi_k - \cos(\phi_k + \dot{\phi}_k \cdot \Delta t) \right), \\
f_{2,4} &= \frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k} \cdot \left(\sin(\phi_k + \dot{\phi}_k \cdot \Delta t) - \sin \phi_k \right), \\
f_{2,5} &= \frac{\Delta t}{2\dot{\phi}_k} \cdot \left(\cos \phi_k - \cos(\phi_k + \dot{\phi}_k \cdot \Delta t) \right), \\
f_{2,6} &= -\frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k^2} \cdot \left(\cos \phi_k - \cos(\phi_k + \dot{\phi}_k \cdot \Delta t) \right) + \\
&\quad \frac{v_k + \frac{1}{2}a_k \cdot \Delta t}{\dot{\phi}_k} \cdot \left(\sin(\phi_k + \dot{\phi}_k \cdot \Delta t) \Delta t \right), \\
f_{3,3} = f_{4,4} &= 1, \\
f_{3,5} = f_{4,6} &= \Delta t \quad \text{und} \\
f_{5,5} = f_{6,6} &= 1.
\end{aligned} \tag{6.44}$$

Alle übrigen Werte von $f_{i,j}$ sind gleich Null.

Betrachtet man für die Bewegungsschätzung lediglich die Lage des Centroiden, so vereinfacht sich der Zusammenhang zwischen Mess- und Zustandsvektor entsprechend und man erhält für die Jacobi-Matrix der Systemausgangsfunktion

$$\mathbf{H}_k = \frac{\partial \mathbf{h}(\mathbf{x})}{\partial (x'_c, x'_c, v, \phi, a, \dot{\phi})} \bigg|_{\mathbf{x}=\mathbf{x}_k} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix}. \tag{6.45}$$

Durch die Vereinfachung reduziert sich die Dimension der Schätzfehler-Kovarianzmatrix entsprechend auf die Größe 6×6 , die Dimension des Messrauschens auf die Größe 2×2 . Auf Basis dieser Annahme lässt sich die Kalmanverstärkung \mathbf{K} zur Aktualisierung der Zustandsschätzung gemäß Gleichung (5.37) berechnen.

Der eigentliche Filterprozess wird in zwei Teilschritte zerlegt. Zunächst erfolgt eine Korrektur jeder einzelnen Stützstelle über den korrespondierenden Messwert. Man definiert hierzu den partiellen Zustandsvektor \mathbf{x}_i , mit

$$\mathbf{x}_i = \begin{bmatrix} x_i & y_i & v & \phi & a & \dot{\phi} \end{bmatrix}^T \quad (6.46)$$

sowie analog den partiellen Messvektor \mathbf{y}_i , mit

$$\mathbf{y}_i = \begin{bmatrix} x_i & y_i \end{bmatrix}^T. \quad (6.47)$$

Es ergibt sich der Korrekturvektor

$$\mathbf{r}_i = \mathbf{K} \cdot (\mathbf{y}_i - \mathbf{h}(\mathbf{x}_i^*)). \quad (6.48)$$

Es lässt sich zeigen, dass der Mittelwert aller Korrekturvektoren der Darstellung in Gleichung (6.40) entspricht. Es gilt

$$\begin{aligned} \mathbf{r}_m &= \frac{1}{N_m} \sum_{i=1}^{N_m} \mathbf{r}_i \\ &= \frac{1}{N_m} \sum_{i=1}^{N_m} \mathbf{K} \cdot (\mathbf{y}_i - \mathbf{h}(\mathbf{x}_i^*)) \\ &= \mathbf{K} \cdot \left(\frac{1}{N_m} \sum_{i=1}^{N_m} \mathbf{p}_i - \frac{1}{N_m} \sum_{i=1}^{N_m} \mathbf{p}_i^* \right) \\ &= \mathbf{K} \cdot \mathbf{t}. \quad (\text{q.e.d}) \end{aligned} \quad (6.49)$$

Es ergibt sich folgender Schätzalgorithmus:

$$\begin{aligned}
\mathbf{x}_{k+1}^* &= \mathbf{f}(\mathbf{x}_k), \\
\mathbf{P}_{k+1}^* &= \mathbf{F}_k \cdot \mathbf{P}_k \cdot \mathbf{F}_k^T + \mathbf{Q}_k, \\
\mathbf{S}_{k+1} &= \mathbf{H}_{k+1} \cdot \mathbf{P}_{k+1}^* \cdot \mathbf{H}_{k+1}^T + \mathbf{R}_{k+1}, \\
\mathbf{K}_{k+1} &= \mathbf{P}_{k+1}^* \cdot \mathbf{H}_{k+1}^T \cdot \mathbf{S}_{k+1}^{-1}, \\
\mathbf{r}_{i_{k+1}} &= \mathbf{K}_{k+1} \cdot \left(\mathbf{y}_{i_{k+1}} - \mathbf{h}(\mathbf{x}_{i_{k+1}}^*) \right), \\
\mathbf{x}_{i_{k+1}}\{1:2\} &= \mathbf{x}_{i_{k+1}}^*\{1:2\} + \mathbf{r}_{i_{k+1}}\{1:2\}, \\
\mathbf{x}_{k+1}\{3:6\} &= \mathbf{x}_{k+1}^*\{3:6\} + \frac{1}{N_m} \sum_{i=1}^{N_m} \mathbf{r}_{i_{k+1}}\{3:6\} \quad \text{und} \\
\mathbf{P}_{k+1} &= (\mathbf{I} - \mathbf{K}_{k+1} \mathbf{H}_{k+1}) \cdot \mathbf{P}_{k+1}^*.
\end{aligned} \tag{6.50}$$

Die Lage des Centroiden $\mathbf{x}_k\{1:2\}$ muss im Zustandsvektor in der Praxis nicht explizit mitgeführt werden, da diese implizit in den Kontur-Stützstellen des Objektes enthalten ist.

6.4.3 Diskussion der Näherung

Um die Belastbarkeit der getroffenen Näherung zu überprüfen, soll eine Betrachtung der Fehlereinflüsse erfolgen:

- Der für die Bewegungsschätzung herangezogene Centroid stimmt nicht notwendigerweise mit dem tatsächlichen Bewegungszentrum des Objektes überein. Führt das Objekt eine Drehbewegung aus, so ergibt sich ein Prädiktionsfehler für die einzelnen Kontur-Stützstellen, dessen Größe durch den Abstand vom tatsächlichen Drehzentrum beeinflusst wird.
- Die Vernachlässigung der Rotation in Gleichung (6.40) führt dazu, dass Änderungen des Kurswinkels einzig über den zeitlichen Verlauf der Translation \mathbf{t} bestimmt werden können, wodurch das Einschwingverhalten des Kurswinkels bzw. der Kurswinkelgeschwindigkeit negativ beeinflusst wird.
- Durch die auf den Centroiden reduzierte Darstellung des Zustands- und Messvektors wird eine mittlere Unsicherheit für die Lage aller Stützstellen angenommen. Aufgrund des Messprinzips der Sensoren (vgl. Abschnitt 6.1.3) gilt jedoch für jede Stützstelle messtechnisch eine eigene Unsicherheit.

Als positiver Effekt der Näherungslösung gilt anzuführen, dass über die Ausgleichsrechnung in (6.40) bereits eine Minimierung des Messrauschens erfolgt. Bei geeignet vielen Stützstellen begrenzt dies den Einfluss von einzelnen Messausreißern auf die Bewegungsschätzung.

Zur Beurteilung des Algorithmus wurden einige Simulationen mit bekannter Eingangsgröße durchgeführt. In Abbildung 6.9 wurde der Algorithmus auf Basis einer Simulation mit $N_p = 4$ Konturpunkten (Rechteck-Form) getestet. Auf die Messung der Konturpunktskoordinaten wurde künstlich ein ideales, normalverteiltes Messrauschen mit einer Varianz von $0,1 \text{ m}^2$ gegeben. Es werden die Schätzwerte und Istwerte für die Geschwindigkeit, Beschleunigung, den Kurswinkel sowie die Kurswinkelgeschwindigkeit gegenübergestellt. Simuliert wurde eine gleichförmig beschleunigte Bewegung bis zur Zeit $t = 3 \text{ s}$, dann eine abrupte Beschleunigungsänderung auf Null sowie eine konstante Kurswinkelgeschwindigkeit von $20 \frac{^\circ}{\text{s}}$, zunächst bei idealer Ebene-2-Assoziation.

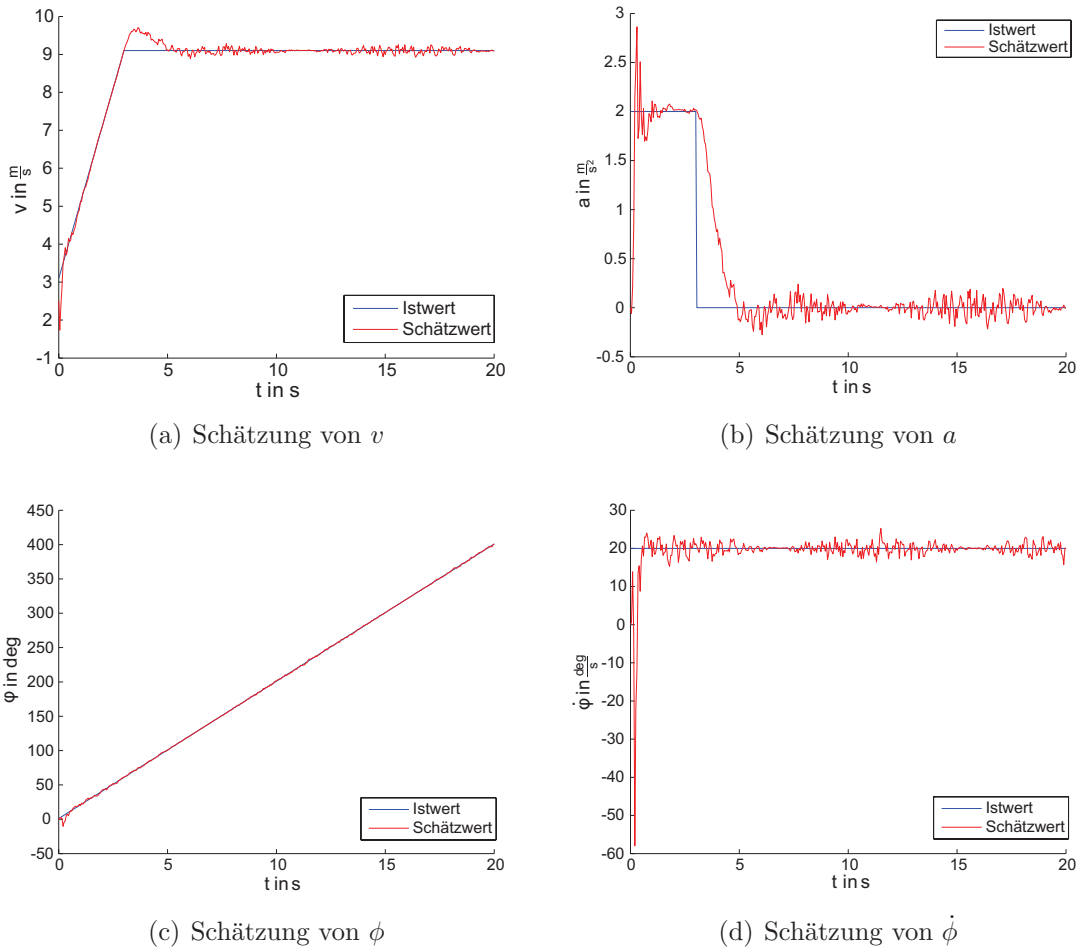


Abb. 6.9: Freiform-Tracking bei idealer Ebene-2-Assoziation

Das Filter kann trotz der gewählten Vereinfachungen dem tatsächlichen Verlauf der Zustandsgrößen folgen. Die Schätzgenauigkeit liegt im Bereich der Erwartungen, die Ableitungen höherer Ordnung (Beschleunigung, Kurswinkelgeschwindigkeit) sind erwartungsgemäß vom Einfluss des Messrauschens stärker betroffen.

In Abb. 6.10 wurde die Ebene-2-Assoziation künstlich verschlechtert. Nach dem Zufallsprinzip wurden 30 Prozent der Assoziationen ausgelassen, so dass in der Zustandsschätzung die Mittelung der Korrekturvektoren über entsprechend weniger Stützstellen erfolgt, wodurch sich eine Divergenz zwischen dem realen und dem über die Näherungslösung angenommenen Bewegungszentrum ergibt. Wie zu erwarten ist, wirkt sich die Störung der Ebene-2-

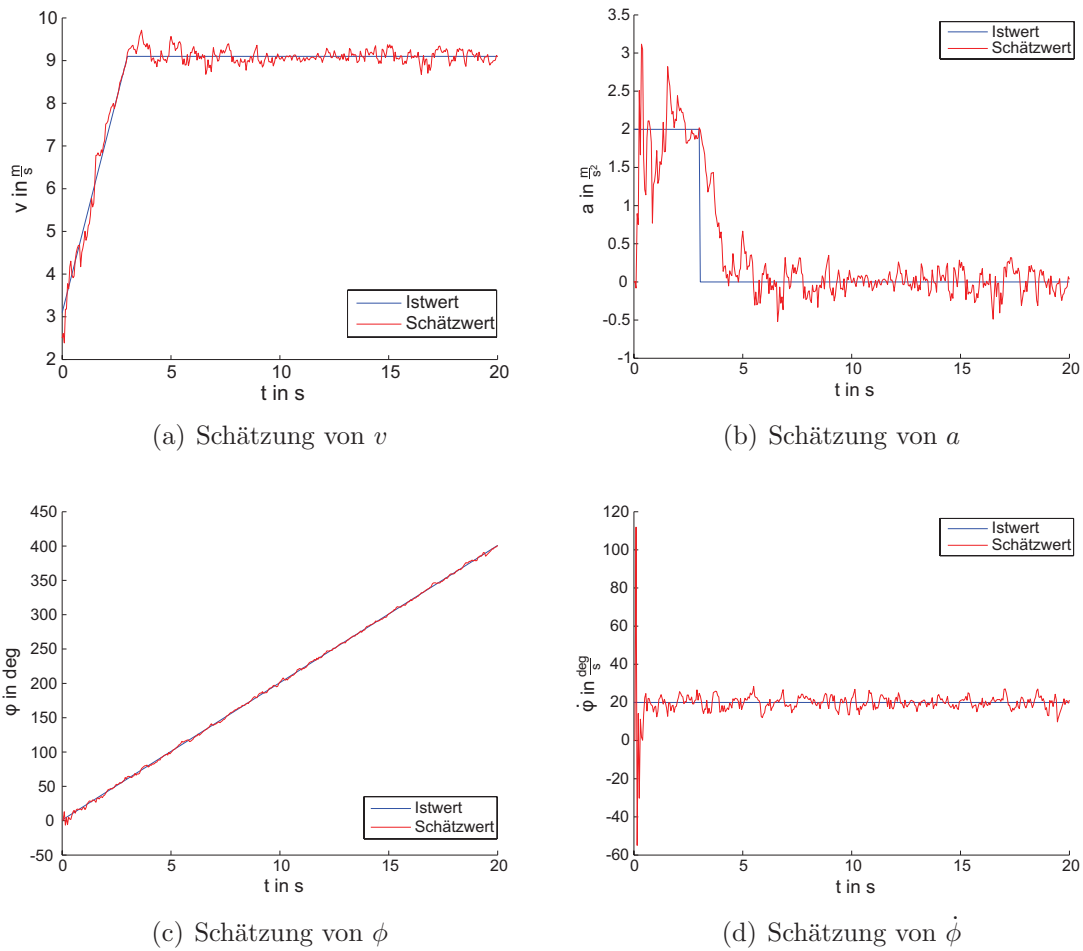


Abb. 6.10: Freiform-Tracking bei zufällig gestörter Ebene-2-Assoziation

Assoziation negativ auf die Schätzgüte der abgeleiteten Zustandsgrößen aus. Das Messrauschen gewinnt zwar an Einfluss, dennoch ist nach wie vor eine konsistente Zustandsschätzung möglich.

Eine weitere in der Praxis übliche Fehlersituation ist eine systematische Störung der Ebene-2 in der Art, dass nur ein Teilbereich des Ziels durch das Sensorsystem beobachtet wird. Es ergibt sich ein systematischer Offset zwischen realem und angenommenen Drehzentrum (Abb. 6.11). Die Störung drückt sich wie erwartet in einem Bias auf der Geschwindigkeitsschätzung





(a) Schätzung von v (b) Schätzung von a (c) Schätzung von ϕ (d) Schätzung von $\dot{\phi}$

Abb. 6.11: Freiform-Tracking bei systematisch gestörter Ebene-2-Assoziation

aus. Dies ist dadurch zu erklären, dass durch die unterschiedlichen Drehpunkte in jedem Schätzfilterzyklus eine zusätzliche Translationskomponente entsteht (vgl. Abb. 6.8), welche irrtümlich als Geschwindigkeitsdifferenz interpretiert wird. Die Größe des Offsets hängt vom Abstand der Drehpunkte sowie vom Betrag der Kurswinkelgeschwindigkeit ab. In der Praxis ist die Drehrate der Objekte vergleichsweise gering und/oder ihre räumliche Ausdehnung eher klein, so dass dem praktischen Einsatz des Algorithmus nichts im Wege steht.

6.5 Adaptives Pretracking zur Objektinitialisierung

Es erweist sich als besondere Herausforderung des urbanen Umfelds, dass mit steigender Komplexität der Situation auch die Häufigkeit von Fehlzielen (sog. Geistermessungen) der einzelnen Sensorsysteme deutlich zunimmt. Neben zufälligen Detektionsfehlern erschweren hierbei insbesondere systematische Messfehler die Interpretation des Fahrzeugumfeldes. Diese werden ausgelöst durch die fehlende vertikale Auflösungsfähigkeit der zur Verfügung stehenden Sensorkomponenten, welche in Anwesenheit von Unebenheiten oder stärkeren Gefälleunterschieden zu einer stabilen Erfassung unerwünschter Bodenreflexionen führen. Die Radarsensoren sind zusätzlich anfällig für starke Reflektoren im Fahrprofil (z.B. Kanaldeckel).

Es ergibt sich die Notwendigkeit zur Vorfilterung der Sensordaten, um unerwünschte Fehlziele im Umfeldmodell mit entsprechend unnötigen oder sogar gefährlichen Reaktionen des autonomen Fahrzeugs zu vermeiden. Als Filterkriterien kommen hierbei folgende Möglichkeiten in Betracht:

- Zufällige Detektionsfehler können durch eine zeitliche Plausibilisierung der Messdaten eliminiert werden. Ist ein vom Sensor geliefertes Objekt über mehrere Zyklen hinweg stabil, so steigt die Wahrscheinlichkeit für ein real vorhandenes Hindernis.
- Da im vorliegenden Fall mehrere Sensorsysteme mit redundanten Beobachtungsbereichen zum Einsatz kommen, lässt sich parallel eine Zielbestätigung über verschiedene Sensorsysteme hinweg umsetzen.

In Anwesenheit von bewegten Objekten setzen beide Mechanismen voraus, dass Sensordaten über verschiedene Beobachtungszeiträume hinweg eindeutig zugeordnet werden können. Dies wird realisiert über einen vorgeschalteten, simplen Tracking-Algorithmus. Ein im Rahmen der Ebene-1-Assoziation nicht zugeordnetes Messobjekt erzeugt zunächst einen sog. Pretrack, welcher unter Verwendung einer punktförmigen Objektbeschreibung

$$\mathbf{x}_{pre} = \begin{bmatrix} x & y & v_x & v_y \end{bmatrix}^T \quad (6.51)$$

und linearem Bewegungsmodell

$$\mathbf{x}_{pre_{k+1}} = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \mathbf{x}_{pre_k} \quad (6.52)$$

einem klassischen Kalmanfilter zugeführt wird. Als Bezugspunkt wird der dem eigenen Fahrzeug dichteste Konturpunkt des Messvektors aufgefasst. Die notwendige Datenzuordnung erfolgt analog Abschnitt 6.3 unter Vernachlässigung der Objektausdehnung. Um sowohl die zeitliche als auch die redundanzbasierte Plausibilisierung der Sensordaten zu ermöglichen, wird die Definition des Pretracks erweitert durch

Definition 6.2 (Pretrack) *Ein Pretrack besteht aus:*

- *Einem Zustandsvektor \mathbf{x}_{pre} mit der zugehörigen Kovarianzmatrix \mathbf{P}_{pre} ,*
- *einem Zählerstand c zur Akkumulierung der Bestätigungsmessungen und*
- *einer Liste $L = \begin{bmatrix} S_1 & \dots & S_j \end{bmatrix}$ zur Speicherung der beteiligten Sensortypen.*

Die Adaption des Pretrackings auf die Lage eines potentiellen Ziels im Erfassungsbereich der Sensoren wird durch verschiedene Plausibilisierungszonen Z_i ermöglicht. Diese sind über die Vorgabe eines Randpolygons \mathbf{P} frei definierbar (vgl. Abb. 6.12).

Definition 6.3 (Plausibilisierungszone:) Eine Plausibilisierungszone Z_i besteht aus

- dem Randpolygon (Gültigkeitsbereich) $\mathbf{A} = [\mathbf{a}_1, \dots, \mathbf{a}_n]$,
- dem Modifikator m und
- der Bedingung B .




Abb. 6.12: Plausibilisierungszonen zur Trackinitialisierung

Über den Modifikator m sowie die Bedingung B wird eine zonenabhängige Aktivierungslogik definiert, welche für die eigentliche Trackinitialisierung erfüllt sein muss.

Der Modifikator drückt die Mindestanzahl von Bestätigungen durch eines der Sensorsysteme aus, die für eine Aktivierung erforderlich sind. Die Bedingung B spezifiziert die notwendige Beteiligung der vorhandenen Sensoren und ist der Form

$$B = (\text{Sensor 1} \text{ oder } \text{Sensor 2}),$$

$$B = (\text{Sensor 1} \text{ und } \text{Sensor 2}),$$

$$B = (\text{Sensor 1} \text{ und nicht } (\text{Sensor 1} \text{ oder } \text{Sensor 2}))$$

oder ähnlichen Kombinationen boolscher Algebra. Es lässt sich so explizit die Beteiligung oder Nicht-Beteiligung eines Sensors fordern. Dies ermöglicht die gezielte Unterdrückung von Geistermessungen eines Sensors in Abhängigkeit von deren Position. Der adaptive Schwellwert c_{adp} für die Zielinitialisierung errechnet sich auf Basis dieser Darstellung zu

$$c_{adp} = c_{min} + \sum_{i=1}^{N_z} \begin{cases} 0 & \text{falls } B_i = 0 \\ m_i & \text{falls } (B_i = 1) \cap (\mathbf{x} \in Z_i) \end{cases} . \quad (6.53)$$

Die Mindestanzahl der Beobachtungen für eine erfolgreiche Zielinitialisierung wird durch die untere Grenze c_{min} festgelegt.

6.5.1 Optimierung durch Kopplung mit Befahrbarkeitsanalyse

Eine weitere Minimierung unerwünschter Bodenreflexionen der LIDAR-Sensorik lässt sich durch Kopplung der Trackinitialisierung mit der in Kapitel 7 vorgestellten Fahrbereichsanalyse erzielen. Im Verlauf der Fahrbereichsanalyse wird eine Höhenkarte der Fahrzeugumgebung erzeugt, welche zur Plausibilisierung der objektgebenden Sensoren herangezogen werden kann. Die Messdaten werden dazu unter Berücksichtigung der Sensorkalibrierung in eine dreidimensionale, erdfeste Koordinatendarstellung überführt (vgl. Abb. 6.13) und können somit direkt mit der Höhenkarte der Fahrzeugumgebung verglichen werden. Wertet man




Abb. 6.13: Plausibilisierung gegen das vertikale Fahrprofil

parallel zur Höhenkarte die Befahrbarkeit des Untergrundes mit aus, so lassen sich folgende Informationen zur Plausibilisierung ausnutzen:

- Die mittlere Differenz zwischen den z -Koordinaten (Objekthöhe) der Messpunkte und den korrespondierenden Höhenmesswerten der Kartendarstellung.
- Die mittlere Befahrbarkeit im kartenbasierten Umfeldmodell an der Stelle der Messpunkte.

Liegt ein Messobjekt dicht bei oder sogar unterhalb der berechneten Höhenkarte und wurde an derselben Stelle ein hohes Maß an Befahrbarkeit bestimmt, so kann dieses als unerwünschte Bodenreflexion eliminiert werden.

7 Kartenbasiertes Umfeldmodell zur Fahrbereichsanalyse

Ziel der kartenbasierten Fahrbereichsanalyse ist es, auf Basis einer modellfreien Beschreibung für jedes diskrete Element des Fahrzeugumfelds eine Klassifikation in die Zustände „befahrbar“ und „unbefahrbar“ vorzunehmen. Als befahrbar wird hierbei die Fahrbahnoberfläche definiert, als unbefahrbar alle übrigen Bereiche.

Um die Klassifikation zu ermöglichen, werden zwei Umfeldmerkmale herangezogen, welche sich in der Praxis als vergleichsweise stabil und somit für eine eindeutige Zuordnung gut einsetzbar erwiesen haben.

- Es kann davon ausgegangen werden, dass die Fahrbahn im urbanen Bereich durch Bordsteine oder vertikal deutlich ausgeprägte Strukturen des Randbereiches begrenzt ist. Das vertikale Profil der Fahrbahn selbst ist hingegen weitgehend glatt, so dass über lokale Änderungen der Höhe (vertikaler Gradient) eine Unterscheidung von Fahrbahn und Randbereich erfolgen kann.
- Fehlt eine ausgeprägte vertikale Struktur im Randbereich (z.B. Begrenzung durch Grünstreifen), so unterscheidet sich zumindest die Farbe der Fahrbahn deutlich von der des Randbereiches. Die Klassifikation des Untergrundes kann somit durch Analyse des charakteristischen Farbprofils unterstützt werden.

Setzt man voraus, dass die Befahrbarkeit ein zeitinvariantes Umfeldmerkmal ist, so eignet sich das in Kapitel 5.3.1 vorgestellte Prinzip der Belegungskarten in besonderem Maße für die zeitliche Integration der eingehenden Merkmale. Notwendig ist die Überführung der Befahrbarkeit in eine äquivalente probabilistische Beschreibungsform. Da im Rahmen der Merkmalsextraktion aus den zur Verfügung stehenden Messdaten auch mit widersprüchlichen Eingangsdaten zu rechnen ist, wird im vorliegenden Fall einer evidenztheoretischen Modellierung (vgl. Abschnitt 5.3.5) der Vorzug gegeben. Für jedes diskrete Element $z(i, j)$ der kartenbasierten Darstellung wird die Dempster-Shafer-Verteilung $m_{z(i, j)}$ der Befahrbar-

keit definiert zu

$$\begin{aligned} m_{z(i,j)}[B] &= m[befahrbar], \\ m_{z(i,j)}[U] &= m[unbefahrbar] \quad \text{und} \\ m_{z(i,j)}[K] &= m[unbekannt / keine Aussage]. \end{aligned} \tag{7.1}$$

Es ergibt sich die in Abb. 7.1 gezeigte Darstellung, wobei die Dempster-Shafer Massenverteilung mit den Farbwerten rot (unbefahrbar), grün (befahrbar) und blau (unbekannt) kodiert wurde.




Abb. 7.1: Ergebnis der kartenbasierten Befahrbarkeitsanalyse

7.1 Datenfluss und prinzipieller Ablauf

Für die Befahrbarkeitsanalyse werden die Messdaten der in Kapitel 4.1.1 dargestellten industriellen Laserscanner sowie des Farbkamerasystems herangezogen. Die korrekte Aktualisierung der Karte setzt ferner den durch die Ortungsplattform ermittelten Fahrzeug-Zustandsvektor voraus. Die Weiterverarbeitung der Messdaten erfolgt in mehreren Schritten, welche wie folgt miteinander verbunden sind:

- Die Position und Orientierung des Fahrzeugs im kartenbasierten Umfeldmodell wird mit jedem Zeitschritt neu bestimmt. Die Karte wird entsprechend der Eigenbewegung aktualisiert, so dass ein gültiger Kartenausschnitt ausreichender Größe um das Fahrzeug herum verfügbar ist (vgl. Abschnitt 7.2).

- Die Abstands-Messwerte der Laserscanner werden in das Bezugskordinatensystem der Karte transformiert. Die Karte wird entlang der Gerade vom Ursprung des Sensorkordinatensystems bis zum Endpunkt der Messung aktualisiert (vgl. Abschnitt 7.3.1). Durch die Eigenbewegung des Versuchsträgers und Messung zu verschiedenen Zeitschritten wird eine Höhenkarte der Fahrzeugumgebung aufgebaut.
- Die Höhenkarte wird einer Interpolation und Gradientenanalyse (vgl. Abschnitt 7.3.3) unterzogen, um die Klassifikation in befahrbare und unbefahrbare Abschnitte vorzubereiten. Gebiete mit hohem Gradienten lassen auf Bordsteinkanten, Randobjekte oder sonstige Hindernisse schließen, Gebiete mit gleichmäßigem Höhenprofil deuten hingegen auf die Fahrbahnoberfläche hin.
- Die Gradienteninformation wird in eine Dempster-Shafer-Massenverteilung überführt (vgl. Abschnitt 7.4.3) und diese über das Prinzip der Belegungsgitter in der Karte aufintegriert. Es resultiert eine Befahrbarkeitsklassifikation auf alleiniger Basis der Gradientendaten.
- Die Befahrbarkeit auf Basis der Gradientendaten wird genutzt, um direkt vor dem Fahrzeug ein Areal maximaler Befahrbarkeit zu ermitteln. Es wird davon ausgegangen, dass dieses mit hoher Wahrscheinlichkeit der Fahrbahnoberfläche entspricht. Das Areal wird in den Bildbereich des Farbkamerasystem projiziert und dient als Suchbereich der Farbanalyse.
- Die Farbanalyse weist jedem Bildpunkt eines vom Kamerasystem erzeugten Farbbildes ein quantitatives Maß der Befahrbarkeit zu. Ausgangspunkt ist das charakteristische Farbprofil innerhalb des zuvor bestimmten Suchbereiches, welcher auf das gesamte Bild ausgedehnt wird (vgl. Abschnitt 7.4).
- Die Ergebnisse der Farbanalyse werden unter Berücksichtigung der Höhenkarte in die kartenbasierte Umfelddarstellung projiziert. Jedem Bildpunkt wird eine korrespondierende Zelle der digitalen Karte zugeordnet.
- Das durch die Farbanalyse bestimmte Maß der Befahrbarkeit wird in eine Dempster-Shafer-Massenverteilung überführt und über das Prinzip der Belegungsgitter in der Karte aufintegriert. Es resultiert die probabilistische Befahrbarkeitsaussage auf Basis der Farbähnlichkeit.
- Die beiden Befahrbarkeitsaussagen aus Gradientenfeld und Farbähnlichkeit werden über ihre Dempster-Shafer Darstellung fusioniert. Das Ergebnis sowie die zugrundeliegende Höhenkarte wird den übergeordneten Algorithmen zur Bahnplanung sowie

der objektbasierten Hinderniserkennung zum Zwecke der optimierten Zielinitialisierung (vgl. Abschnitt 6.5) übergeben.

Der skizzierte Datenfluss führt zu einer Erweiterung des kartenbasierten Umfeldmodells um mehrere Informationsebenen, welche als Speicher für die einzelnen Zwischenschritte des Algorithmus verwendet werden. Abb. 7.2 stellt den Zusammenhang graphisch dar. Es ergibt

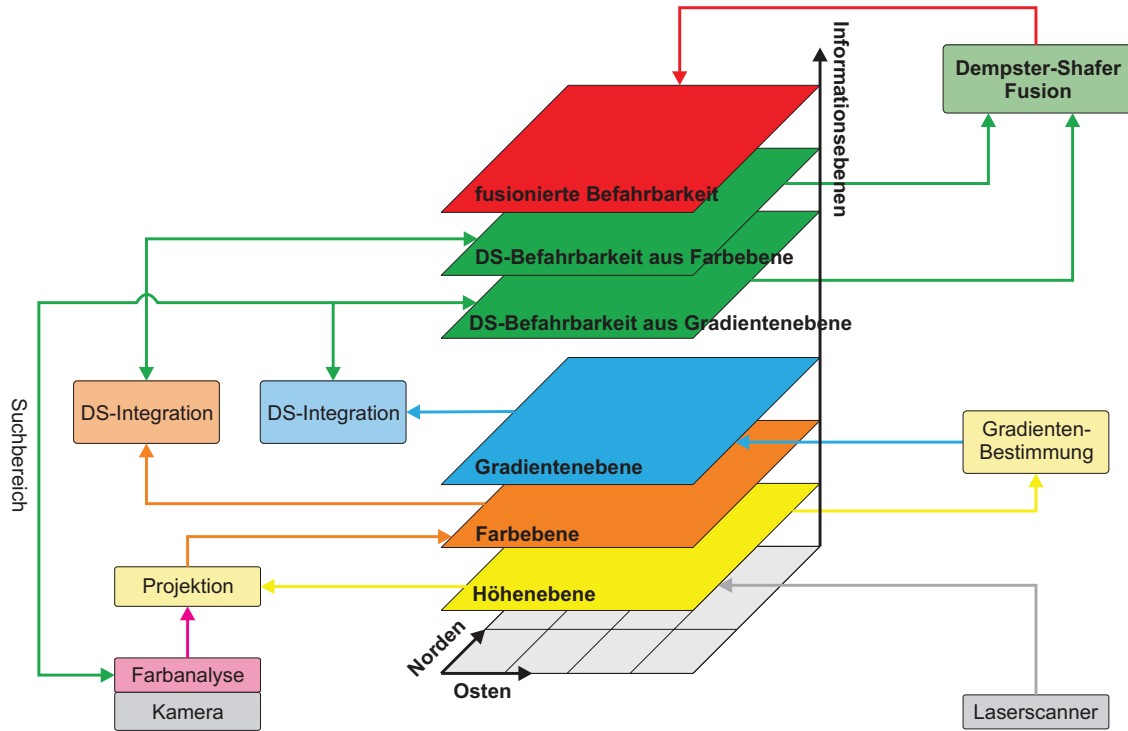


Abb. 7.2: Informationsebenen und Datenfluss

sich folgende Definition des kartenbasierten Umfeldmodells:

Definition 7.1 (Umfeldmodell zur Befahrbarkeitsanalyse) Der Merkmalsraum Γ einer jeden Zelle im Umfeldmodell ist gegeben durch:

$$\Gamma = \left\{ h_{z(i,j)}, g_{z(i,j)}, f_{z(i,j)}, m_{z(i,j)}^{grad}, m_{z(i,j)}^{farb}, m_{z(i,j)}^{fus} \right\} \quad (7.2)$$

Hierbei ist

- $h_{z(i,j)}$ die lokale Höhe der Umgebung in Bezug auf den Ursprung des Weltkoordinatensystems an der Stelle (i, j) ,
- $g_{z(i,j)} = \frac{\partial h_{z(i,j)}}{\partial i \partial j}$ der lokale Gradient des Höhenfelds (die lokale Höhendifferenz),

- $f_{z(i,j)}$ der Farbhähnlichkeitswert nach dessen Projektion auf die Karte,
- $m_{z(i,j)}^{grad}$ die Dempster-Shafer Massenverteilung als Maß der Befahrbarkeit auf Basis des Gradientenfeldes,
- $m_{z(i,j)}^{farb}$ die Dempster-Shafer Massenverteilung als Maß der Befahrbarkeit auf Basis der Farbhähnlichkeit und
- $m_{z(i,j)}^{fus}$ die Dempster-Shafer Massenverteilung als Maß der Befahrbarkeit auf Basis der fusionierten Farb- und Gradientenanalyse.

7.2 Datenstruktur und Verwaltung der Karte

Bei einer praktischen Umsetzung des kartenbasierten Umfeldmodells ergeben sich zwei Möglichkeiten für die Darstellung der Karte sowie die Berücksichtigung der Fahrzeug-Eigenbewegung.

- Die Definition einer fahrzeugfesten Kartendarstellung erfordert eine Korrektur des Karteninhalts mit jeder Veränderung der Fahrzeugposition, da die Merkmale des kartenbasierten Umfeldmodells statisch gegenüber dem inertialen Weltkoordinatensystem und nicht gegenüber dem mitbewegten Fahrzeugkoordinatensystem sind (vgl. Anhang A). In einer praktischen Implementierung muss die gesamte Datenbasis der Karte (blaue Zellen in Abb. 7.3) entsprechend der Fahrzeugbewegung neu berechnet werden, was einen entsprechend hohen Rechenaufwand zur Folge hat.




Abb. 7.3: Fahrzeugfeste Kartendarstellung

- Die Definition einer erdfesten Kartendarstellung erfordert demgegenüber lediglich eine Verschiebung des Fahrzeugs in der Karte. Setzt man allerdings voraus, dass im

Bereich der automobilen Applikation der Aktionsradius des Fahrzeugs praktisch unbegrenzt ist, so ergibt sich die Notwendigkeit einer Begrenzung der Informationsmenge und somit die Einführung eines begrenzten Kartenausschnitts. Bei einer Bewegung des Versuchsträgers muss nicht mehr die gesamte Datenbasis der Karte aktualisiert werden, sondern diejenigen Zellen, welche neu in den gültigen Kartenausschnitt eintreten (vgl. Abb. 7.4).




Abb. 7.4: Ortsfeste Kartendarstellung

Es ist offensichtlich, dass eine fahrzeugfeste Implementierung wenig geeignet für die Darstellung der statischen Befahrbarkeit ist. Unabhängig davon stellt die hohe Zellanzahl über die quadratisch mit der Auflösung anwachsende Größe der Datenstruktur hohe Anforderungen an eine effiziente Umsetzung der Algorithmen. In diesem Kontext ist eine Betrachtung der zum Einsatz kommenden Rechnerarchitektur für die Implementierung sinnvoll.

7.2.1 Rechnerarchitektur und Speicherlayout

Die verwendeten PC-basierten Rechnersysteme weisen eine Von Neumann-Rechnerarchitektur [60] auf (vgl. Abb. 7.5). Der Prozessor mit seinen Registern für die Berechnung ist über den Speichercontroller und Speicherbus mit dem externen Hauptspeicher verbunden. Da Zugriffe auf den externen Hauptspeicher vergleichsweise langsam sind, sind zwei Cache-Speicher (Level-1 und Level-2 Cache) vorgesehen, welche als Zwischenspeicher für häufig verwendete Größen dienen. Die Cache-Speicher sind wesentlich schneller adressierbar als der Hauptspeicher, bieten aber nur einer vergleichsweise geringe Kapazität (z.B. Intel Pentium 4 Prescott 2M Chipsatz, L1-Cache 16 KByte, L2-Cache 2 MByte [64]). Es liegt daher im Interesse einer effizienten Implementierung, dass Zellen der digitalen Kartendarstellung, auf die nacheinander zugegriffen wird, möglichst in einem zusammenhängenden Speicherbereich des Rechnersystems alloziert werden.

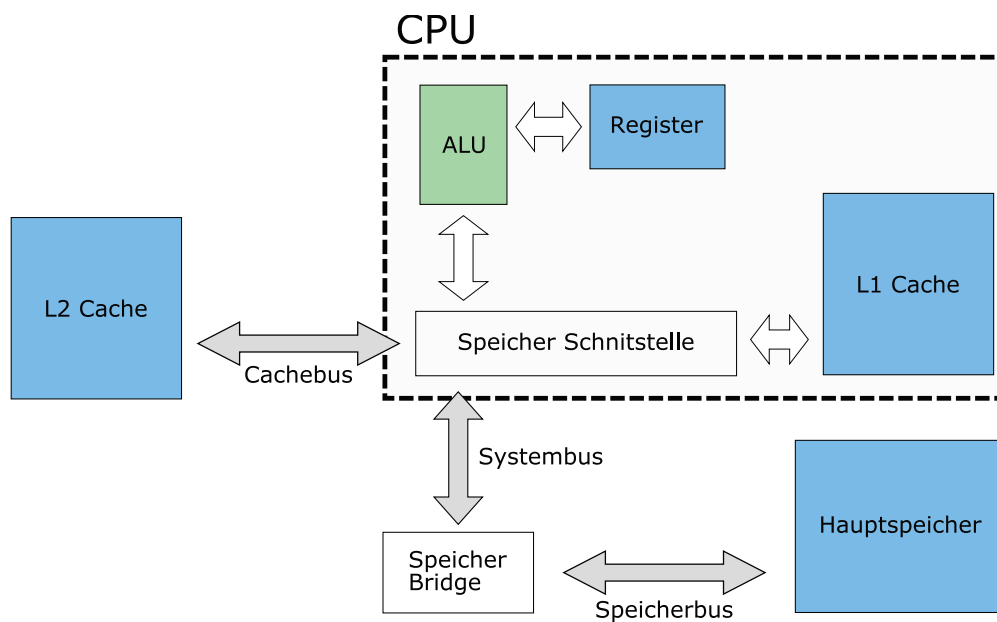


Abb. 7.5: Von Neumann-Rechnerarchitektur

Im vorliegenden Fall erfolgt der Großteil der Zugriffe auf die Datenstruktur entlang einer Geraden zwischen Sensorursprung und Messpunkt. Eine naive Allokierung der Karte als blockförmige Matrixstruktur würde zu einem Speicherlayout entlang der Matrixspalten führen. In Abb. 7.6a ist beispielhaft der Zugriff entlang einer gegebenen Aktualisierungsrichtung dargestellt. Mit jedem Zeilenwechsel ist der Zugriff auf einen neuen Speicherblock (farbig hervorgehoben) notwendig, die Blöcke liegen zudem bei großer Ausdehnung der Karte bezüglich ihrer Adressierung weit voneinander entfernt. Es kommt zu einer hohen Anzahl von Zugriffen auf den langsameren externen Hauptspeicher.

Geht man davon aus, dass sich keine Vorzugsrichtung für die Aktualisierung definieren lässt, da die Orientierung des Fahrzeugs beliebig ist und die Sensoren einen hohen Öffnungswinkel abdecken, lässt sich eine effizientere Implementierung finden. Die Allokierung erfolgt in diesem Fall in der Art, dass quadratische Zellpakete blockweise zusammengefasst werden. Ist die Blockgröße kompatibel mit den Größen des Level-1 bzw. Level-2 Cache, führt dies zu einer deutlichen Reduktion externer Speicherzugriffe, wie in Abb. 7.6b dargestellt ist. Der Einfluss des Speicherlayouts hat somit signifikanten Einfluss auf den erzielbaren Datendurchsatz und muss sorgfältig auf die Zielhardware angepasst werden [71].

Für eine Wahl der optimalen Block- und Zellgröße wurde die in Abb. 7.7 dargestellte Leistungsanalyse durchgeführt. Um signifikante Aussagen zu erhalten, wurden strahlförmige Aktualisierungen ausgehend vom Zentrum eines Kreises in der Mitte der Karte auf den Kreisbogen mit dem Radius von 100 Metern in Schritten von einem Grad unternommen. Die Größe der Karte (Gesamtanzahl aller Zellen) wird bei einer Auflösung von einem viertel Meter kon-

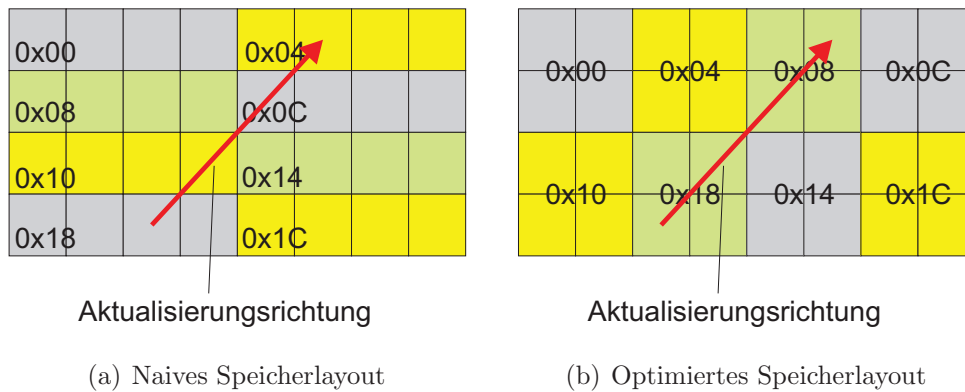


Abb. 7.6: Speicherlayout für optimierten Datenzugriff

stant gehalten, die Größe bzw. Anzahl der Blöcke (Teilgitter) jedoch variiert. Es lässt sich so für eine gegebene Zellgröße die optimale Blockgröße bzw. Anzahl der Teilgitter ermitteln, um den maximalen Datendurchsatz zu erzielen.




Abb. 7.7: Datendurchsatz der Karte über Anzahl der Teilgitter

7.2.2 Optimierte Datenstruktur für die Echtzeit-Anwendung

Durch die Vorgabe einer blockförmigen Speicherstruktur lässt sich zusätzlich ein optimierter Ablauf für die Verschiebung des gültigen Kartenausschnitts erzielen. Man führt hierzu als Bezugsblock diejenige Zellgruppe ein, welche die aktuelle Fahrzeugposition beinhaltet.

Die Navigation innerhalb der Karte erfolgt stets relativ zu diesem Bezugsblock, welcher den Aufpunkt (Bezugspunkt) auf die Datenstruktur darstellt. Der Zusammenhang zwischen dem Bezugspunkt und der korrespondierenden Position im erdfesten Koordinatensystem wird in der Karte mitgeführt. Die Fahrzeug-Eigenposition kann innerhalb des Bezugsblocks kontinu-

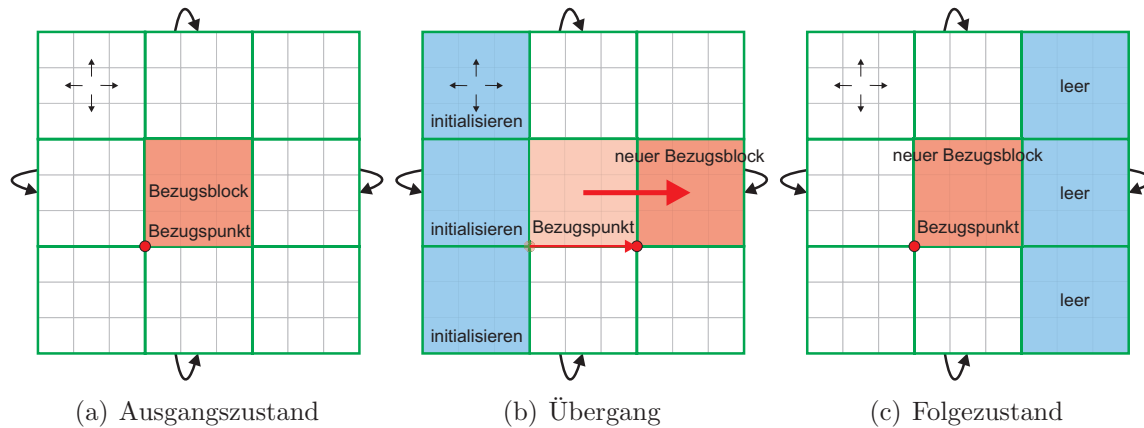


Abb. 7.8: Ringförmig verkettete Karte in Blockstruktur

ierlich aktualisiert werden, ohne dass eine Neuinitialisierung am Rand des Kartenausschnitts (vgl. Abb.7.8a bis 7.8c) erforderlich ist. Da durch den strahlförmigen Zugriff stets benachbarte Zellen adressiert werden, erfolgt zusätzlich eine zweidimensional-ringförmige Verkettung aller Zellen untereinander. Verlässt das Fahrzeug den Bezugsblock, so wird am virtuellen Horizont des Kartenausschnittes der Zellinhalt auf einen Standardwert zurückgesetzt. Diese blockweise Neuinitialisierung verringert die Anzahl der notwendigen Speicher-Einzelzugriffe und trägt somit zu einer Steigerung des Datendurchsatzes bei.

7.3 Höhenbasierte Befahrbarkeitsabschätzung

Die Datenstruktur der Karte liefert den algorithmischen Rahmen für den Eintrag der Messdaten. Die spezifische Eintragestrategie orientiert sich am Messprinzip. Die verwendeten LIDAR-Scanner liefern eine Reihe von Abstands-Messwerten entlang ihres Öffnungswinkels. Es kann vorausgesetzt werden, dass der Pfad zwischen Sensorursprung und dem Messpunkt frei von Hindernissen ist. Neben dem eigentlichen Endpunkt der Messung ist somit auch der Freibereich im Verlauf des Strahlengangs eine verwertbare Messinformation.

7.3.1 Aktualisierung des Höhenprofils

Der Anfangs- und Endpunkt eines jeden LIDAR-Abstandsmesswertes wird zunächst unter Ausnutzung der Sensorkalibrierung sowie des Fahrzeug-Zustandsvektors in die erdfeste Koordinatendarstellung

$$\mathbf{p}_{a/e} = \begin{bmatrix} x_{a/e} & y_{a/e} & z_{a/e} \end{bmatrix} \quad (7.3)$$

überführt (vgl. Anhang A). Mit dem bekannten Bezugspunkt der Kartendarstellung ergibt sich die Lage der beiden Punkte in diskreten Kartenkoordinaten zu

$$\begin{pmatrix} i_{a/e} \\ j_{a/e} \\ h_{a/e} \end{pmatrix} = \begin{pmatrix} \text{round} \left(\frac{x_{a/e} - x_{ref}}{\Delta x} \right) + i_{ref} \\ \text{round} \left(\frac{y_{a/e} - y_{ref}}{\Delta y} \right) + j_{ref} \\ z_{a/e} \end{pmatrix}, \quad (7.4)$$

Es ist zu beachten, dass die Höhe h als kontinuierliche Messgröße mitgeführt wird, da die Karte eine zweidimensionale Datenstruktur aufweist und keine Diskretisierung in Z-Richtung vorgenommen wird. Die Aktualisierung der Karte erfolgt strahlförmig vom Anfangs- zum Endpunkt, wobei die Höhe zwischen den Zellen linear interpoliert wird. Gemäß dem Sensormodell kann kein Messwert des in der Karte zuvor gespeicherten Höhenprofils größer als der Verlauf des augenblicklich betrachteten Strahlenganges sein. Messausreißer oder Interpolationsfehler vorangegangener Messzyklen werden auf diese Weise korrigiert. Der Höhenwert des Endpunktes wird in der Karte abgelegt. Es ergibt sich die in Abb. 7.9 dargestellte Vorgehensweise.




Abb. 7.9: Eintragestrategie der LIDAR-Daten

7.3.2 Raycasting-Algorithmus

Für die strahlförmige Kartenaktualisierung lässt sich der nach seinem Entwickler benannte Bresenham-Algorithmus [19] nutzen. Der Algorithmus wurde für die Steuerung von digitalen Plottern entwickelt. Um die Rechenzeit zu minimieren, wurde vollständig auf laufzeitintensive Fließkomma-Arithmetik verzichtet.

Als Eingangsgrößen des Algorithmus werden der Anfangs- und Endpunkt (i_a, j_a) bzw. (i_e, j_e) des zu aktualisierenden Strahls benötigt. Man verschiebt nun den Ursprung eines Ersatzkoordinatensystems i', j' in den Startpunkt und erhält die neuen Gitterkoordinaten:

$$\begin{aligned}(i'_a, j'_a) &= (0, 0) \quad \text{und} \\ (i'_e, j'_e) &= (i_e - i_a, j_e - j_a).\end{aligned}$$

In Abb. 7.10 ist das Vorgehen für eine Gerade im ersten Oktanten des Koordinatensystems dargestellt. Der kontinuierliche Strahlverlauf muss durch die diskrete Kartenstruktur




Abb. 7.10: Raytracing-Algorithmus nach Bresenham

approximiert werden. Man wählt dazu diejenigen Zellen, deren Abstand zum Strahlengang minimal ist. Für das dargestellte Beispiel im ersten Oktanten erfolgt hierzu in jedem Schritt eine Inkrementierung in Richtung i' , in Abhängigkeit vom Verlauf der Geraden zusätzlich eine Inkrementierung in Richtung j' . Jeder Ursprungspunkt P_r auf der approximierten Geraden hat damit zwei mögliche Folgerpunkte P_{r+1} und Q_{r+1} . Der korrekte Folgerpunkt kann über einen Vergleich der beiden Lotabstände p_r und q_r von P_{r+1} und Q_{r+1} zum kontinuierlichen

Strahlverlauf berechnet werden. Es gilt folgende Vorschrift für die Wahl der Folgezelle:

$$\begin{aligned} i'_{r+1} &= i'_r + 1 \quad \text{und} \\ j'_{r+1} &= \begin{cases} j'_r + 1 & \text{falls } p_r \leq q_r \\ j'_r & \text{falls } p_r > q_r \end{cases}. \end{aligned} \quad (7.5)$$

Betrachtet man die beiden ähnlichen Dreiecke D_1 und D_2 in Abb. 7.10, so gilt für die beiden Hypothenusen u_r und v_r das gleiche Größenverhältnis wie für die Lotabstände p_r und q_r selbst. Diese berechnen sich durch

$$\begin{aligned} u_r &= (j'_r + 1) - j'_s \quad \text{und} \\ v_r &= j'_s - j'_r. \end{aligned} \quad (7.6)$$

Hierbei ist (i'_s, j'_s) der Schnittpunkt der Hypothenusen mit dem kontinuierlichen Strahlengang. Den Größenvergleich der Hypothenusen drückt man nun durch den Fehlerterm Δ_r aus. Man erhält

$$\Delta_r = (v_r - u_r). \quad (7.7)$$

Für die Approximation gilt entsprechend

$$\begin{aligned} i'_{r+1} &= i'_i + 1 \quad \text{und} \\ j'_{r+1} &= \begin{cases} j'_r + 1 & \text{falls } \Delta_r \geq 0 \\ j'_r & \text{falls } \Delta_r < 0 \end{cases}. \end{aligned} \quad (7.8)$$

Da nur das Vorzeichen von Δ_r entscheidet und der Wert i'_e in jedem Falle größer Null ist, gilt ohne Einschränkung

$$\Delta_r = (v_r - u_r) \cdot i'_e. \quad (7.9)$$

Der Schnittpunkt (i'_s, j'_s) ergibt sich zu

$$\begin{aligned} i'_s &= i'_r + 1 \quad \text{und} \\ j'_s &= \frac{j'_e}{i'_e} (i'_r + 1). \end{aligned} \quad (7.10)$$

Das Einsetzen der Gleichungen (7.6) und (7.10) in Gleichung (7.9) führt zu

$$\begin{aligned}
 \Delta_r &= [j'_s - j'_r - (j'_r + 1) + j'_s]i'_e \\
 &= 2j'_s \cdot i'_e - (2j'_r + 1)i'_e. \\
 &= 2(i'_r + 1)j'_e - (2j'_r + 1)i'_e \\
 &= 2i'_r j'_e - 2j'_r i'_e + 2j'_e - i'_e.
 \end{aligned} \tag{7.11}$$

Die Gleichung (7.11) kann rekursiv ausgedrückt werden. Man erhält für den Initialwert mit $i'_r = 0$ und $j'_r = 0$

$$\Delta_r = 2j'_e - i'_e \tag{7.12}$$

sowie für die Folgewerte

$$\begin{aligned}
 \Delta_{r+1} &= \begin{cases} 2(i'_r + 1)j'_e - 2(j'_r + 1)i'_e + 2j'_e - i'_e & \text{für } \Delta_r \geq 0 \\ 2(i'_r + 1)j'_e - 2(j'_r)i'_e + 2j'_e - i'_e & \text{für } \Delta_r < 0 \end{cases} \\
 &= \begin{cases} \Delta_r + 2j'_e - 2i'_e & \text{für } \Delta_r \geq 0 \\ \Delta_r + 2j'_e & \text{für } \Delta_r < 0 \end{cases}.
 \end{aligned} \tag{7.13}$$

Die Vorgehensweise kann für die übrigen Oktanten des Koordinatensystems analog angewendet werden, es muss hierbei lediglich die Zuordnung der Kartenkoordinaten i, j zu den Ersatzkoordinaten i', j' getauscht werden. Man erhält in Abhängigkeit der Strahlrichtung Δi und Δj , mit

$$\Delta i = i_e - i_a \quad \text{und} \tag{7.14}$$

$$\Delta j = j_e - j_a, \tag{7.15}$$

die in Tabelle 7.1 dargestellte Zuordnungstabelle für die Wahl des Ersatzkoordinatensystems.

Es ergibt sich folgender Algorithmus für die Approximation eines beliebigen Strahlengangs:

0. Bestimme die Anfangs- und Endposition des Strahls in der Karte (i_a, j_a) bzw. (i_e, j_e) .
Bestimme die Parameter Δi und Δj .
1. Wähle den Oktanten des Bresenham-Algorithmus und die entsprechende Zuordnung des Ersatzkoordinatensystems gemäß Tabelle 7.1.

Δi	Δj	$ \Delta i - \Delta j $	res. Oktant	i'	j'
≥ 0	≥ 0	≥ 0	1	i	j
≥ 0	≥ 0	< 0	2	j	i
< 0	≥ 0	< 0	3	j	$-i$
< 0	≥ 0	≥ 0	4	$-i$	j
< 0	< 0	≥ 0	5	$-i$	$-j$
< 0	< 0	< 0	6	$-j$	$-i$
≥ 0	< 0	< 0	7	$-j$	i
≥ 0	< 0	≥ 0	8	i	$-j$

Tabelle 7.1: Zuordnung des Ersatzkoordinatensystems

2. Bestimme den Initialfehlerterm Δ_0 , setze $r = 0$.
3. Für $\Delta_r \geq 0$, inkrementiere i' und j' , ansonsten inkrementiere nur i' . Bestimme Δ_{r+1} gemäß Gleichung (7.13). Bestimme für i' und j' die korrespondierenden Kartenkoordinaten i und j . Setze $r = r + 1$.
4. Aktualisiere die Karte an der neuen Position i und j .
5. Falls die Zielposition (i_e, j_e) erreicht wurde, beende den Algorithmus, ansonsten springe zu 3.

Die Leistungsfähigkeit und Flexibilität der Bresenham-Implementierung kann durch die Wahl eines günstigen Programmiermusters deutlich gesteigert werden. Im Allgemeinen ist es dabei wünschenswert, dass der Algorithmus zur Traversalion der Datenstruktur so gestaltet ist, dass unterschiedliche Operationen auf den Daten ausführbar sind, um die Möglichkeit verschiedener Sensormodelle zu realisieren. Im Rahmen einer objektorientierten Realisierung eignet sich hierzu vor allem das in [55] beschriebene Visitor-Prinzip.

Das Visitor-Prinzip wurde ursprünglich für Datenbank-Zugriffe konzipiert und zeichnet sich dadurch aus, dass über eine Trennung von Datenstruktur, Datenauswahl und Aktualisierungsfunktion ein hohes Maß an Modularität geschaffen wird. Die Datenstruktur selbst stellt die Funktion zur Traversalion (die Auswahl der zu aktualisierenden Datensätze) zur Verfügung. Diese ruft für jedes Datenelement eine Methode der Visitor-Schnittstellendefinition auf, welche zur Änderung des Datensatzes verwendet wird.

```

class Visitor {
    virtual bool onRay(float z, Cell &data);
    virtual bool onHit(float z, Cell &data);
};

```

Im konkret vorliegenden Anwendungsfall des Bresenham-Algorithmus werden als Schnittstelle zwei Funktionen definiert, welche die Aktualisierung der Zellen auf und am Ende des Strahlenganges steuern.

Die Visitor-Schnittstelle übergibt die Höhe des Strahlenganges an der aktuell durchlaufenen Zelle sowie eine Referenz auf die Zelle selbst. Innerhalb der frei implementierbaren Funktionen **onRay** und **onHit**, welche von verschiedenen Klassen instantiiert werden können, sind beliebige Operationen möglich. Der Bresenham-Algorithmus implementiert die Traversionsfunktion auf der Datenstruktur

```
void bresenham(DiscreteCoordinate src , DiscreteCoordinate dest ,  
               Visitor &v );
```

und ermöglicht so die notwendige strahlförmige Aktualisierung der Zellen. Von Nachteil bei der Methode ist, dass im Falle verschiedener Schnittstellen-Implementierungen (d.h. verschiedene Sensormodelle) zur Laufzeit entschieden werden muss, welche Funktion im Einzelfall auszuführen ist. Der Vorgang muss bei jedem Methodenaufruf wiederholt werden, was bei einer hohen Anzahl aktualisierter Zellen entsprechend ungünstig ist.

Die Leistungsfähigkeit des Visitor-Musters lässt sich daher deutlich steigern, wenn über die Verwendung von Klassen-Templates der Traversionsfunktion eine Schablone der Aktualisierungsroutine übergeben wird. Man erhält folgende Funktionsdefinition:

```
template<class VISITOR>  
void bresenham(DiscreteCoordinate src , DiscreteCoordinate dest ,  
               VISITOR &v );
```

Die geringe Änderung der Syntax bewirkt eine signifikante Veränderung der Semantik, da durch die Verwendung der Klassen-Templates bereits zur Kompilierungszeit eine Implementierung der Bresenham-Routine für jede verwendete Aktualisierungsfunktion erzeugt wird, so dass die zeitaufwendigen Entscheidungen zur Laufzeit entfallen. Erweitert man das Prinzip der Template-Programmierung noch auf den Ablauf des Bresenham-Algorithmus selbst in der Art, dass für jeden Oktanten eine eigene Funktionsimplementierung erzeugt wird, so lässt sich eine weitere Laufzeitoptimierung erzielen. Das entsprechende Programmierkonzept wird in diesem Falle Template-Metaprogramming genannt [1]. In Abb. 7.11 ist die erzielte Leistungssteigerung durch die optimierten Programmiermuster gegenübergestellt. Es ergibt sich für die Template-Metaprogrammierung im Vergleich zur ursprünglichen Umsetzung des Visitor-Musters eine Leistungssteigerung von über 100 Prozent.




Abb. 7.11: Vergleich verschiedener Programmiermuster

7.3.3 Interpolation und Gradientenanalyse

Die durch den alleinigen Eintrag der LIDAR-Messwerte aufgebaute Höhenkarte ist zunächst unvollständig, da zum einen durch die LIDAR-Sensorik lediglich eine Abtastung entlang zweier Schnittgeraden mit der Fahrbahnebene erfolgt und zum anderen der zeitliche Abstand zwischen zwei Messungen bei hohen Fahrgeschwindigkeiten das Überspringen von einzelnen Zellen verursachen kann. Um eine dichte Höhenkarte zu erhalten, ist eine Interpolation über das unvollständige Höhenprofil notwendig. Da komplexe Algorithmen zur Interpolation (z.B. Delaunay-Triangulation [35]) einen zu hohen Rechenaufwand verursachen, wird ein einfacher zweistufiger Prozess angewendet:

- Zunächst erfolgt eine lokale Interpolation in der direkten Nachbarschaft existierender Messwerte, um kleinere Löcher der Kartendarstellung zu füllen.
- Darauf aufbauend erfolgt die Approximation einer globalen Fahrbahnebene, welche zur Füllung der übrigen Fehlstellen verwendet wird.

Lokale Interpolation

Zur lokalen Interpolation kommt der mit dem Nearest Neighbour Verfahren verwandte zweidimensionale Expand-Algorithmus zum Einsatz. Für jede Zelle ohne gültigen Höhenmesswert wird ein kreisförmiger Suchbereich in der Karte definiert, welcher in seine Oktanten zerlegt wird. Ausgehend vom Zentrum wird in jedem Oktanten die erste Zelle ermittelt, welche

einen gültigen Höhenmesswert enthält. Aus den auf diese Weise ermittelten Höhenmesswerten der Oktanten wird der Mittelwert gebildet und dieser als interpolierter Wert in der Karte abgelegt. Der Höhenwert wird als interpoliert gekennzeichnet, um eine ungewollte Vervielfältigung interpolierter Werte zu vermeiden. Der Vorgang ist in Abb. 7.12 veranschaulicht. In Rot ist hierbei die zu interpolierende Zelle gekennzeichnet, in Blau dargestellt sind Zellen mit korrekt gemessenen Höhenwerten.




Abb. 7.12: Expand-Algorithmus

Globale Approximation der Fahrbahnebene

Da in weiten Teilen von einem ebenen Fahrzeugumfeld ausgegangen werden kann, soll zur Rekonstruktion der übrigen Höhenwerte eine globale Fahrbahnebene bestimmt werden. Die Approximation bietet gegenüber einer simplen Null-Höhen-Annahme den Vorteil, dass im Falle von Gefällstrecken eine optimierte Rekonstruktion des vertikalen Fahrbahnprofils möglich ist. Für einen beliebigen Punkt \mathbf{p}_i auf dieser Ebene gilt gemäß der Schreibweise mit Ebenen-Normalenvektor \mathbf{n} und Abstand vom Ursprung d

$$\mathbf{n} \cdot \mathbf{p}_i - d = 0. \quad (7.16)$$

Stehen genügend Stützstellen entlang der Fahrbahnebene zur Verfügung, so lässt sich eine Least-Squares Schätzung der Ebenenparameter durchführen. Für jede Stützstelle \mathbf{p}_i wird ein skalarcs Gütemaß w_i eingeführt, welches als Gewicht in die Ausgleichsrechnung mit einfließt. Die gewichtete quadratische Fehlersumme der Stützstellen \mathbf{p}_i ergibt sich zu

$$R(n_x, n_y, n_z, d) = \sum_{i=1}^N w_i \cdot e^T \cdot e = \sum_{i=1}^N w_i \cdot (n_x x_i + n_y y_i + n_z z_i - d)^2. \quad (7.17)$$

Für die Minimierung wird zunächst der Abstandsparameter d betrachtet. Es gilt

$$\begin{aligned}
 \frac{\partial R(n_x, n_y, n_z, d)}{\partial d} &= 0 \quad \Leftrightarrow \\
 \frac{\partial \sum_{i=1}^N w_i \cdot (n_x x_i + n_y y_i + n_z z_i - d)^2}{\partial d} &= 0 \quad \Leftrightarrow \\
 -2 \sum_{i=1}^N w_i (n_x x_i + n_y y_i + n_z z_i - d) &= 0 \quad \Leftrightarrow \\
 \frac{1}{\sum_{i=1}^N w_i} \sum_{i=1}^N w_i (n_x x_i + n_y y_i + n_z z_i) &= d \quad \Leftrightarrow \\
 \frac{1}{\sum_{i=1}^N w_i} \begin{pmatrix} \sum_{i=1}^N w_i x_i \\ \sum_{i=1}^N w_i y_i \\ \sum_{i=1}^N w_i z_i \end{pmatrix} \cdot \mathbf{n} &= d.
 \end{aligned} \tag{7.18}$$

Die gesuchte Fahrbahnebene verläuft also durch den gewichteten Centroiden \mathbf{p}_c aller Stützstellen. Es gilt

$$\mathbf{p}_c = \frac{1}{\sum_{i=1}^N w_i} \begin{pmatrix} w_i x_i \\ w_i y_i \\ w_i z_i \end{pmatrix} = \begin{pmatrix} x_c \\ y_c \\ z_c \end{pmatrix}. \tag{7.19}$$

Ein Einsetzen von d in Gleichung (7.17) liefert

$$\begin{aligned}
 R(n_x, n_y, n_z) &= \sum_{i=1}^N w_i (n_x x_i + n_y y_i + n_z z_i - n_x x_c - n_y y_c - n_z z_c)^2, \\
 &= \sum_{i=1}^N w_i (n_x (x_i - x_c) + n_y (y_i - y_c) + n_z (z_i - z_c))^2.
 \end{aligned} \tag{7.20}$$

Um die triviale Lösung $\mathbf{n} = \mathbf{0}$ bei der Minimierung auszuschließen, wird als Nebenbedingung

$$\phi(n_x, n_y, n_z) = 1 - n_x^2 - n_y^2 - n_z^2 = 0 \tag{7.21}$$

gefordert. Eine Minimierungsaufgabe mit Nebenbedingung führt zur Methode des Lagrange-Multiplikators [89]. Es ergibt sich die zu minimierende Lagrange-Funktion $\Phi(n_x, n_y, n_z, \lambda)$

zu

$$\begin{aligned}
 \Phi(n_x, n_y, n_z, \lambda) &= R(n_x, n_y, n_z) + \lambda \cdot \phi(n_x, n_y, n_z) \\
 &= \sum_{i=1}^N w_i (n_x x_i + n_y y_i + n_z z_i - n_x x_c - n_y y_c - n_z z_c)^2 + \\
 &\quad \lambda \cdot (1 - n_x^2 - n_y^2 - n_z^2).
 \end{aligned} \tag{7.22}$$

Deren Minimierung nach \mathbf{n} liefert

$$\begin{aligned}
 \frac{\partial \Phi(n_x, n_y, n_z, \lambda)}{\partial n_x} &= 2 \sum_{i=1}^N w_i [n_x(x_i - x_c) + n_y(y_i - y_c) + n_z(z_i - z_c)] (x_i - x_c) - 2\lambda n_x, \\
 \frac{\partial \Phi(n_x, n_y, n_z, \lambda)}{\partial n_y} &= 2 \sum_{i=1}^N w_i [n_x(x_i - x_c) + n_y(y_i - y_c) + n_z(z_i - z_c)] (y_i - y_c) - 2\lambda n_y, \\
 \frac{\partial \Phi(n_x, n_y, n_z, \lambda)}{\partial n_z} &= 2 \sum_{i=1}^N w_i [n_x(x_i - x_c) + n_y(y_i - y_c) + n_z(z_i - z_c)] (z_i - z_c) - 2\lambda n_z.
 \end{aligned} \tag{7.23}$$

Setzt man die Ableitungen gleich Null, so ergibt sich folgendes Gleichungssystem:

$$\mathbf{P} \cdot \mathbf{n} - \lambda \cdot \mathbf{n} = 0. \tag{7.24}$$

Die Matrix \mathbf{P} ist die Kovarianzmatrix der Stützstellen \mathbf{p}_i . Es gilt

$$\mathbf{P} = \begin{bmatrix} \sum_{i=1}^N w_i (x_i - x_c)^2 & \sum_{i=1}^N w_i (x_i - x_c)(y_i - y_c) & \sum_{i=1}^N w_i (x_i - x_c)(z_i - z_c) \\ \sum_{i=1}^N w_i (x_i - x_c)(y_i - y_c) & \sum_{i=1}^N w_i (y_i - y_c)^2 & \sum_{i=1}^N w_i (y_i - y_c)(z_i - z_c) \\ \sum_{i=1}^N w_i (x_i - x_c)(z_i - z_c) & \sum_{i=1}^N w_i (y_i - y_c)(z_i - z_c) & \sum_{i=1}^N w_i (z_i - z_c)^2 \end{bmatrix}. \tag{7.25}$$

Gleichung (7.24) stellt sich als Lösung des Eigenwertproblems der Matrix \mathbf{P} dar mit

$$[\mathbf{P} - \lambda \cdot \mathbf{I}] \cdot \mathbf{n} = 0. \tag{7.26}$$

Zur Bestimmung der Eigenwerte und -vektoren kann auf gängige mathematische Methoden der linearen Algebra [49] zurückgriffen werden. Hierbei ist derjenige Eigenvektor mit dem kleinsten Eigenwert die optimale Lösung für \mathbf{n} [126].

Extraktion der Stützstellen für die globale Interpolation

Kritisch bei der Extraktion der Stützstellen ist die Unterdrückung von Höhenmesswerten außerhalb der Fahrbahnebene (z.B. Hindernisse). Diese dürfen (falls überhaupt) nur mit einem geringen Gewicht in die globale Approximation einfließen, um eine Verfälschung der Schätzparameter zu vermeiden. Um dies zu ermöglichen, wird auf das in der Karte vorhandene probabilistische Befahrbarkeitsmodell zurückgegriffen. Innerhalb eines vordefinierten Suchbereiches vor dem Fahrzeug werden N Stützstellen extrahiert, als Gewicht wird das Maß der Befahrbarkeit aus der Dempster-Shafer Darstellung gewählt, so dass sich eine Wichtung zwischen Null (unbefahrbar) und Eins (voll befahrbar) ergibt. Hierdurch wird sichergestellt, dass Umfeldbereiche mit niedriger Befahrbarkeit im Rahmen der Ausgleichsrechnung weitgehend unterdrückt werden.

Um eine signifikante Stichprobenmenge sicherzustellen, wird ein Schwellwert für die Summe aller Gewichte w_i definiert, unterhalb dessen die gesamte Stichprobenmenge verworfen wird. Die Ausgleichsrechnung zur Approximation startet nur, wenn

$$\sum_{i=1}^N w_i \geq N \cdot p_{min} \cdot B_{min} \quad (7.27)$$

sichergestellt ist. Der Wert p_{min} ist der prozentuale Anteil der Stützstellen, für die eine minimale Befahrbarkeit von B_{min} gefordert wird.

Gradientenanalyse


Für die Berechnung der lokalen Unebenheit (Gradient des Höhenfeldes) kommt der in der klassischen Bildverarbeitung [46] häufig verwendete Sobel-Operator zum Einsatz. Dieser definiert sich als zweidimensionale Faltung der Höhenkarte mit den Operatoren

$$\mathbf{O}_{Sobel_x} = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad \text{und} \quad \mathbf{O}_{Sobel_y} = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}. \quad (7.28)$$


Diese ermitteln zunächst getrennt den Gradienten in i und j Richtung der Höhenkarte. Da nur eine quantitative Angabe der lokalen Höhenänderung benötigt wird, werden die beiden Komponenten per Summation zusammengefasst, so dass sich der Gradient an der Stelle (i, j) errechnet zu

$$g_{z(i,j)} = O_{Sobel_x} \otimes h_{z(i,j)} + O_{Sobel_y} \otimes h_{z(i,j)}. \quad (7.29)$$

Der Vorgang ist in Abb. 7.13a und 7.13b dargestellt.



(a) Höhenkarte



(b) Gradientenfeld

7.3.4 Probabilistische Interpretation der Gradientendarstellung

Hohe Ausschläge im Gradientenfeld werden durch Sprünge in der Höhenkarte verursacht, was wiederum auf Bordsteinkanten oder ähnliche Hindernisse schließen lässt. Der Straßenverlauf selbst ist demgegenüber vergleichsweise glatt. Sanfte Höhenübergänge (z.B. Rampen, Bodenwellen) verursachen lediglich einen geringen Anstieg des lokalen Gradienten. Diese Beobachtung motiviert die Definition des probabilistischen Sensormodells, welches die Gradientenkarte in eine äquivalente Dempster-Shafer Massenverteilung der Befahrbarkeit überführt. Hierbei ist die Befahrbarkeit innerhalb gewisser Schwellwerte umgekehrt proportional zur Höhe des Gradienten, so dass sich folgende Modellierung ergibt:

- Es existiert ein unterer Schwellwert für den Gradienten, unterhalb dessen maximale Befahrbarkeit gefordert wird. Dies berücksichtigt die Tatsache, dass sanfte An- oder Abstiege im Höhenprofil keinen negativen Einfluss auf die Befahrbarkeit des Untergrundes haben.
- Es existiert ein oberer Schwellwert für den Gradienten, oberhalb dessen maximale Unbefahrbarkeit gefordert wird.
- Die Sicherheit über die Tatsache, dass das Gelände unbefahrbar ist, steigt mit der Höhe des Gradienten an. Im Übergangsbereich zwischen Befahrbarkeit und Unbefahrbarkeit herrscht eine hohe Unsicherheit, da geringe Messfehler die Aussage verfälschen können.
- Es existiert ein gewisses Grundmaß an Unsicherheit.

Man erhält auf Basis dieser Annahmen folgende Funktionsdefinition für die gradientenbasierte Befahrbarkeit m^{grad} :

$$\begin{aligned}
 m^{grad}[B] &= \begin{cases} B_{max}, & |g_{z(i,j)}| \leq g_{min} \\ 0, & g_{min} < |g_{z(i,j)}| \leq g_{max} \\ 0, & |g_{z(i,j)}| > g_{max} \end{cases} , \\
 m^{grad}[U] &= \begin{cases} 0, & |g_{z(i,j)}| \leq g_{min} \\ \frac{U_{max}}{g_{max}-g_{min}} \cdot (|g_{z(i,j)}| - g_{min}), & g_{min} < |g_{z(i,j)}| \leq g_{max} \\ U_{max}, & |g_{z(i,j)}| > g_{max} \end{cases} \quad \text{und} \\
 m^{grad}[K] &= 1 - m^{grad}[B] - m^{grad}[U]. \quad (7.30)
 \end{aligned}$$

Der Verlauf der resultierenden Massenverteilung ist in Abb. 7.13c bis 7.13e dargestellt.




Abb. 7.13: Gradientenbasiertes probabilistisches Sensormodell

In der Praxis haben sich die Werte $g_{min} = 0.15$, $g_{max} = 0.9$ und $B_{max} = U_{max} = 0.9$ bewährt. Dies entspricht einer maximalen Befahrbarkeit bis zu einem Gefälle von ca. 30 Grad sowie einer maximalen Unbefahrbarkeit bei Höhendifferenzen größer 90 Zentimetern zwischen benachbarten Zellen. Es ist hierbei irrelevant, ob ein positiver oder negativer Gradient vorliegt. Im Grenzbereich $|g| \approx g_{min}$ zeigt sich der Vorteil des Dempster-Shafer-Ansatzes gegenüber einer klassischen Bayes'schen Betrachtungsweise. Es ist möglich, einem Gradienten größer g_{min} ein kleines Maß an Unbefahrbarkeit zuzuordnen, ohne dass der verbleibende Anteil direkt der Befahrbarkeit zufällt. Es lässt sich hiermit die Unsicherheit der Klassifikation zum Ausdruck bringen.

7.4 Farbbasierte Befahrbarkeitsabschätzung

Der fahrbare Bereich im urbanen Umfeld ist üblicherweise bezüglich Farbe und oder Textur deutlich vom Randbereich oder eventuell vorhandenen Hindernissen zu unterscheiden. Diese Beobachtung ist Ansatzpunkt einer farbbasierten Befahrbarkeitsabschätzung, welche auf Basis einer Farbaufnahme des Fahrzeugumfelds die Klassifikation einzelner Bildbereiche bezüglich deren Zugehörigkeit zur Fahrbahnoberfläche anstrebt.

7.4.1 Klassifikation im Bildbereich

Steht ein Farbmuster der Fahrbahnoberfläche zur Verfügung, so lässt sich das charakteristische Farbprofil extrahieren und zum Zwecke der Klassifikation nutzen. Hierbei wird auf eine Segmentierung des Bildes im Farbraum zurückgegriffen [21, 23]. Bei dem in [118] beschriebenen Verfahren wird zunächst unter Nutzung alternativer Sensordaten ein Suchbereich mit sicherer Befahrbarkeit definiert. Dieser wird wie in Abschnitt 7.1 durch Auswertung der gradientenbasierten Befahrbarkeit auf Basis der LIDAR-Messdaten generiert. Darauf aufbauend folgen eine Reihe von Bearbeitungsschritten zur Bildsegmentierung:

- **Extraktion des charakteristischen Farbprofils:**

Der Farbraum des Suchbereiches wird als kontinuierlicher Zustandsraum mit den Größen r (rot), g (grün) und b (blau) aufgefasst. Für jeden Bildpunkt i ergibt sich ein Zustandsvektor \mathbf{x}_i zu

$$\mathbf{x}_i = \begin{bmatrix} r & g & b \end{bmatrix}_i^T. \quad (7.31)$$

Es wird angenommen, dass die statistische Verteilung der N Farbwerte im Suchbereich einer Mischung M verschiedener Normalverteilungen entspricht. Die Wahrscheinlichkeitsverteilung jedes Bildpunkts ergibt sich demnach zu

$$p(\mathbf{x}_i) = \sum_{j=1}^M c_j \cdot N[\mathbf{x}_i; \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j] \quad \text{mit} \quad \sum_{j=1}^M c_j = 1. \quad (7.32)$$

Hierbei sind c_j , $\boldsymbol{\mu}_j$ und $\boldsymbol{\Sigma}_j$ die zunächst unbekannten Parameter $\boldsymbol{\Theta}_j$ (Wichtung, Mittelwert und Varianz) des Farbprofils. Es gilt, eine Maximum-Likelihood-Schätzung für den Parameterraum $\boldsymbol{\Theta} = [\boldsymbol{\Theta}_1, \dots, \boldsymbol{\Theta}_M]$ unter Verwendung der Farbwerte \mathbf{x}_i im Suchbereich

zu bestimmen. Über die Mischung der Normalverteilungen ergibt sich die Likelihood eines Parametersatzes zu

$$L(\Theta | \mathbf{x}_1, \dots, \mathbf{x}_N) = \prod_{i=1}^N \sum_{j=1}^M c_j \cdot N[\mathbf{x}; \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j] \quad (7.33)$$

bzw. in logarithmischer Darstellung

$$\log L(\Theta | \mathbf{x}_1, \dots, \mathbf{x}_N) = \sum_{i=1}^N \log \left(\sum_{j=1}^M c_j \cdot N[\mathbf{x}; \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j] \right). \quad (7.34)$$

Eine explizite Maximierung der Log-Likelihood in Gleichung (7.34) wird durch die Summenbildung im Logarithmus erschwert. Stellt man jedoch Annahmen über die Zugehörigkeit jedes Farbwertes zu einer der Normalverteilungen auf, so lässt sich der in [15] beschriebene EM-Algorithmus (Expectation Maximization) entwickeln. Aus Gründen der Übersichtlichkeit sei im Folgenden lediglich der resultierende Algorithmus angegeben.

1. Teile die N Farbwerte des Suchbereiches zufällig in M Gruppen auf, bestimme für jede Gruppe den Mittelwert $\boldsymbol{\mu}_j$ sowie die Varianz $\boldsymbol{\Sigma}_j$. Setze die Gewichte aller Gruppen c_j auf den Wert $\frac{1}{M}$.
2. Bestimme die Log-Likelihood der aktuellen Parametrierung Θ gemäß Gleichung (7.34).
3. Berechne einen neuen Parametersatz Θ' zu

$$\begin{aligned} c'_j &= \frac{1}{N} \sum_{i=1}^N p_{ij}, \\ \boldsymbol{\mu}'_j &= \frac{\sum_{i=1}^N \mathbf{x}_i \cdot p_{ij}}{\sum_{i=1}^N p_{ij}}, \\ \boldsymbol{\Sigma}'_j &= \frac{\sum_{i=1}^N (\mathbf{x}_i - \boldsymbol{\mu}'_j)^2 p_{ij}}{\sum_{i=1}^N p_{ij}}, \quad \text{mit} \\ p_{ij} &= \frac{c_j \cdot N[\mathbf{x}_i; \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j]}{\sum_{l=1}^M c_l \cdot N[\mathbf{x}_i; \boldsymbol{\mu}_l, \boldsymbol{\Sigma}_l]}. \end{aligned} \quad (7.35)$$

Bestimme für jeden erzeugten Teilparametersatz Θ_j die Anzahl der Bildpunkte n_j , welche zur Stützung der betrachteten Normalverteilung beitragen (Abstand vom Mittelwert $\boldsymbol{\mu}_j$).

4. Bestimme die Log-Likelihood $L(\Theta')$ für den neuen Parametersatz gemäß Gleichung (7.34).
5. Liegt die Differenz der beiden Log-Likelihoods $L(\Theta)$ bzw $L(\Theta')$ unterhalb eines vorgegebenen Schwellwertes, beende den Algorithmus und gib den aktuellen Parametersatz Θ' sowie die Werte n_j zurück. Andernfalls setze $\Theta = \Theta'$ und beginne mit Schritt 2.

• **Verwaltung und Adaption des Farbprofils:**

Die im ersten Schritt erhaltenen Farbprofile des Suchbereiches werden über mehrere Zeitschritte hinweg gesammelt. Im globalen Parameterspeicher wird eine Anzahl $K > M$ charakteristischer Normalverteilungen vorgehalten. Die in jedem Zeitschritt neu bestimmten Teilparametersätze werden mit den bereits im System vorhandenen verglichen. Eine Aufnahme in den globalen Parameterspeicher erfolgt nach folgenden Kriterien:

- Liegt der Abstand einer neu bestimmten und einer bereits gespeicherten Gaußverteilung unterhalb eines bestimmten Schwellwertes, so erfolgt eine Korrektur der gespeicherten Parametrierung mit dem neuen Parametersatz. Als Gütemaß wird der Mahalanobis-Abstand $d(i, j)$ der beiden Verteilungen i und j mit

$$d(i, j) = (\boldsymbol{\mu}_i - \mathbf{m}\mathbf{u}_j)^T \cdot (\boldsymbol{\Sigma}_i + \boldsymbol{\Sigma}_j)^{-1} \cdot (\boldsymbol{\mu}_i - \mathbf{m}\mathbf{u}_j) \quad (7.36)$$

herangezogen. Die korrigierten Parameter ergeben sich zu

$$\begin{aligned} \boldsymbol{\mu}_i' &= \frac{n_i \boldsymbol{\mu}_i}{n_i + n_j} + \frac{n_j \boldsymbol{\mu}_j}{n_i + n_j}, \\ \boldsymbol{\Sigma}_i' &= \frac{n_i \boldsymbol{\Sigma}_i}{n_i + n_j} + \frac{n_j \boldsymbol{\Sigma}_j}{n_i + n_j} \quad \text{und} \\ n_i' &= n_i + n_j. \end{aligned} \quad (7.37)$$

- Liegt der Abstand oberhalb des vorgegebenen Schwellwertes, so wird die Normalverteilung mit der geringsten Unterstützung n_i durch den neuen Teilparametersatz Θ_j ersetzt.

Zum Abschluss eines Zyklus werden für alle gespeicherten Parametersätze die Unterstützungen n_i dekrementiert, um eine zeitliche Degression einzuführen. Der Algorithmus ist so befähigt, sich auf geänderte Umweltbedingungen schneller einzustellen.

• **Bewertung des gesamten Bildbereiches**

Ist die Bestimmung des globalen Parametersatzes abgeschlossen, so erfolgt eine Bewer-

tung jedes einzelnen Bildpunktes \mathbf{x}_i des Gesamtbildes über die einzelnen Normalverteilungen Θ_i . Liegt ein Bildpunkt innerhalb eines frei definierbaren Konfidenzintervalls, so wird er als befahrbar eingestuft und im umgekehrten Fall als unbefahrbar.

Die Robustheit im urbanen Umfeld lässt sich durch eine Reihe von Farbfiltren [13, 105] erhöhen, um auftretende Schlagschatten, Fahrbahnmarkierungen oder ähnliches nicht irrtümlich als unbefahrbar einzustufen. Der vergleichsweise aufwendige EM-Algorithmus lässt sich ferner durch den in [82] beschriebenen K-Means-Algorithmus ersetzen, wodurch der Rechenzeitbedarf verringert werden kann. In der hier gewählten Implementierung wird statt einer binären Klassifikation die Farbhähnlichkeit gewichtet im Wertebereich von 0 (maximaler Unterschied) bis 1 (identisches Farbprofil) zurückgegeben. In den Abbildungen 7.14a bis 7.14c sind die Ergebnisse des Algorithmus mit und ohne Optimierung dargestellt. Die Grauwerte symbolisieren die Ähnlichkeit mit dem Farbprofil des Fahrbahnbelages, rot markierte Bereiche wurden als ungültig gekennzeichnet (z.B. Schlagschatten).



Abb. 7.14: Ergebnisse der Farbanalyse

7.4.2 Transformation in das kartenbasierte Umfeldmodell

Um eine Verarbeitung der farbbasierten Klassifikation im kartenbasierten Umfeldmodell zu ermöglichen, ist eine Projektion von der Pixelebene des zweidimensionalen Bildausschnitts auf die Kartenebene notwendig (vgl. Abb. 7.15). Der über die Brennweite normierte Bildpunkt ausgedrückt im Koordinatensystem der Kamera lässt sich berechnen zu [59]

$$\begin{aligned} z'_B &= 1, \\ y'_B &= \frac{y_P - cc_2}{f} \quad \text{und} \\ x'_B &= \frac{x_P - cc_1 - \alpha_c \cdot y'_B}{f}. \end{aligned} \tag{7.38}$$




Abb. 7.15: Projektion auf die Kartenebene

Hierbei sind (x_p, y_p) die Pixelkoordinaten, f ist die Brennweite der Optik und cc_1 sowie cc_2 ist das optische Zentrum der Kamera auf dem Imager-Chip. Da der Ursprung des Kamerakoordinatensystems im Brennpunkt liegt, ergibt sich der Richtungsvektor der Projektionsgerade in Kamerakoordinaten zu

$$\mathbf{d}_S = \begin{bmatrix} -x'_B & -y'_B & -z'_B \end{bmatrix}^T. \quad (7.39)$$

Sind die Kalibrierung der Kamera (Einbaulage und Orientierung) in Bezug auf das Fahrzeugkoordinatensystem und auch der Fahrzeug-Zustandsvektor bekannt, so ergibt sich die Projektionsgerade des Bildpunktes gemäß Anhang A.2 in Weltkoordinaten zu

$$\mathbf{p}_W = \mathbf{t}_{WF} + \mathbf{T}_{WF} \cdot \mathbf{t}_{FS} + \lambda \cdot \mathbf{T}_{WF} \cdot \mathbf{T}_{FS} \cdot \mathbf{d}_S. \quad (7.40)$$

Dabei ist \mathbf{p}_W ein beliebiger Punkt auf der Geraden und λ die Skalierung entlang des Richtungsvektors. Bringt man die Projektionsgerade zum Schnitt mit der gemäß Abschnitt 7.3.3 approximierten Fahrbahnebene, so erhält man das Gleichungssystem

$$\begin{aligned} 0 &= \mathbf{n} \cdot \mathbf{p}_W - d \iff \\ \lambda &= \frac{d - \mathbf{n} \cdot (\mathbf{t}_{WF} + \mathbf{T}_{WF} \cdot \mathbf{t}_{FS})}{\mathbf{n} \cdot \mathbf{T}_{WF} \cdot \mathbf{T}_{FS} \cdot \mathbf{d}_S}. \end{aligned} \quad (7.41)$$

Erneutes Einsetzen von λ in Gleichung (7.40) führt schließlich zum gesuchten Schnittpunkt des optischen Pfades mit der Fahrbahnebene, welcher in das diskrete Karten-Koordinatensystem überführt werden kann.

Für das Eintragen der farbbasierten Klassifikation erfolgt eine strahlförmige Iteration durch die Karte gemäß Abschnitt 7.3.2. Durchstößt ein in der Karte gespeicherter Höhenwert den Strahlengang des betrachteten Bildpunkts, so erfolgt die Aktualisierung an der korrespondierenden Zelle (vgl. Abb. 7.16), ansonsten wird bis zum berechneten Zielpunkt iteriert.




Abb. 7.16: Eintragen der farbbasierten Klassifikation

7.4.3 Probabilistische Interpretation der farbbasierten Klassifikation

Die probabilistische Interpretation der farbbasierten Klassifikation ist intuitiv. Je ähnlicher ein Bildpunkt dem fahrbaren Untergrund ist, desto höher ist dessen Befahrbarkeit. Der kontinuierliche Wertebereich $f_{z(i,j)}$ des projizierten Grauwertbildes an der Stelle $z(i,j)$ wird in die äquivalente Dempster-Shafer Massenverteilung m^{arb} überführt. Man erhält

$$\begin{aligned} m^{arb}[B] &= B_{max} \cdot f_{z(i,j)}, \\ m^{arb}[U] &= U_{max}(1 - f_{z(i,j)}) \quad \text{und} \\ m^{arb}[K] &= 1 - m^{arb}[B] - m^{arb}[U] = 1 - f_{z(i,j)} \cdot (B_{max} - U_{max}) - U_{max}. \end{aligned} \quad (7.42)$$

Ein Klassifikationsergebnis von 1 (maximale Ähnlichkeit) führt demnach zu maximaler Befahrbarkeit und umgekehrt. Die Skalierung der Zwischengrößen wird linear gewählt. Es gilt hierbei

$$\begin{aligned} B_{max} &\leq 1 \quad \text{und} \\ U_{max} &\leq 1. \end{aligned}$$

Das Vertrauen in die Positiv- und Negativ-Klassifikation lässt sich unabhängig parametrieren. Da in der Praxis schnelle Änderungen der Belichtungsverhältnisse einen vergleichsweise langsamen Einschwingvorgang der farbbasierten Klassifikation zur Folge haben, hat sich insbesondere für die Unbefahrbarkeit ein vergleichsweise hohes Maß an Basis-Unsicherheit bewährt ($U_{max} = 0.6$ und $B_{max} = 0.9$). Es resultiert das in Abb. 7.17a bis 7.17c dargestellte probabilistische Sensormodell.




Abb. 7.17: Farbbasiertes probabilistisches Sensormodell

7.5 Zeitliche Integration und Datenfusion

In einem abschließenden Verarbeitungsschritt werden die Ergebnisse der farb- bzw. gradientenbasierten probabilistischen Sensormodelle über mehrere Messzyklen hinweg in getrennten Ebenen der Karte integriert und die Ebenen schließlich fusioniert. Gemäß Kapitel 5.3.5 kommt hierzu das Dempster'sche Kombinationsgesetz aus Gleichung (5.83) zum Einsatz. Man erhält die getrennte zeitliche Integration der Befahrbarkeit je Zelle $z(i, j)$ zu

$$m_{z(i,j)}^{grad}[B] = \frac{m_{z(i,j)}^{grad}[B] \cdot m_{z(i,j)}^{grad}[B] + m_{z(i,j)}^{grad}[K] \cdot m_{z(i,j)}^{grad}[B] + m_{z(i,j)}^{grad}[B] \cdot m_{z(i,j)}^{grad}[K]}{\eta^{grad}},$$

$$m_{z(i,j)}^{grad}[U] = \frac{m_{z(i,j)}^{grad}[U] \cdot m_{z(i,j)}^{grad}[U] + m_{z(i,j)}^{grad}[K] \cdot m_{z(i,j)}^{grad}[U] + m_{z(i,j)}^{grad}[U] \cdot m_{z(i,j)}^{grad}[K]}{\eta^{grad}} \quad \text{und}$$

$$m_{z(i,j)}^{grad}[K] = 1 - m_{z(i,j)}^{grad}[B] - m_{z(i,j)}^{grad}[U] \quad \text{bzw.} \quad (7.43)$$

$$m_{z(i,j)}^{farb}[B] = \frac{m_{z(i,j)}^{farb}[B] \cdot m_{z(i,j)}^{farb}[B] + m_{z(i,j)}^{farb}[K] \cdot m_{z(i,j)}^{farb}[B] + m_{z(i,j)}^{farb}[B] \cdot m_{z(i,j)}^{farb}[K]}{\eta^{farb}},$$

$$m_{z(i,j)}^{farb}[U] = \frac{m_{z(i,j)}^{farb}[U] \cdot m_{z(i,j)}^{farb}[U] + m_{z(i,j)}^{farb}[K] \cdot m_{z(i,j)}^{farb}[U] + m_{z(i,j)}^{farb}[U] \cdot m_{z(i,j)}^{farb}[K]}{\eta^{farb}} \quad \text{und}$$

$$m_{z(i,j)}^{farb}[K] = 1 - m_{z(i,j)}^{farb}[B] - m_{z(i,j)}^{farb}[U]. \quad (7.44)$$

Der Normierungsterm η in Gleichung (7.43) bzw. (7.44) berechnet sich zu

$$\eta^{grad/farb} = 1 - m_{z(i,j)}^{grad/farb}[B] \cdot m^{grad/farb}[U] - m_{z(i,j)}^{grad/farb}[U] \cdot m^{grad/farb}[B]. \quad (7.45)$$

Die Trennung der Befahrbarkeiten bewirkt eine Entkopplung der stark unterschiedlichen Messfrequenz beider Sensorsysteme, welche beim LIDAR mit ca. 75 Hz ca. fünffach höher im Vergleich zum Kamerasystem ist. Die getrennte Integration und nachgeschaltete Fusion ermöglicht eine gleichberechtigte Auswertung. Die Fusion lässt sich durch eine erneute Anwendung der Dempster'schen Kombinationsregel umsetzen. Man erhält

$$\begin{aligned} m_{z(i,j)}^{fus}[B] &= \frac{m_{z(i,j)}^{grad}[B] \cdot m_{z(i,j)}^{farb}[B] + m_{z(i,j)}^{grad}[K] \cdot m_{z(i,j)}^{farb}[B] + m_{z(i,j)}^{grad}[B] \cdot m_{z(i,j)}^{farb}[K]}{\eta}, \\ m_{z(i,j)}^{fus}[U] &= \frac{m_{z(i,j)}^{grad}[U] \cdot m_{z(i,j)}^{farb}[U] + m_{z(i,j)}^{grad}[K] \cdot m_{z(i,j)}^{farb}[U] + m_{z(i,j)}^{grad}[U] \cdot m_{z(i,j)}^{farb}[K]}{\eta} \quad \text{und} \\ m_{z(i,j)}^{fus}[K] &= 1 - m_{z(i,j)}^{fus}[B] - m_{z(i,j)}^{fus}[U]. \end{aligned} \quad (7.46)$$

Es sei darauf hingewiesen, dass für die fusionierte Befahrbarkeit keine weitere zeitliche Integration notwendig ist, da diese bereits bei der Berechnung der beiden Teilaussagen $m_{z(i,j)}^{grad}$ bzw. $m_{z(i,j)}^{farb}$ erfolgt ist. Neben der resultierenden Befahrbarkeitsaussage $m_{z(i,j)}^{fus}$ ist vor allem auch der Konflikt C , mit

$$C = 1 - \eta = m_{z(i,j)}^{grad}[B] \cdot m_{farb}[U] - m_{z(i,j)}^{grad}[U] \cdot m_{farb}[B] \quad (7.47)$$

von Interesse. Dieser drückt den Widerspruch beider Sensortypen aus. Gebiete mit hohem Konflikt sind ein Zeichen für eine verringerte Güte des Umfeldmodells bzw. ein höheres Maß an Unsicherheit. Dies kann in der übergeordneten Bahnplanung für eine Reduktion der Eigengeschwindigkeit genutzt werden, sollte kein anderer, konfliktfreier Pfad für die Fahrzeugführung möglich sein.

7.6 Anpassung an dynamische Vorgänge

Es ist eine der wesentlichen Einschränkungen des kartenbasierten Umfeldmodells, dass dynamische Veränderungen des Fahrzeugumfelds in Widerspruch zur Ableitung aus dem diskreten Bayes'schen Filteralgorithmus (vgl. Abschnitt 5.3.2) stehen. Treten diese in der Realität dennoch auf, so kann diese Modellverletzung nur langsam durch Korrektur mit aktuellen Messinformationen beseitigt werden. Problematisch ist dies insbesondere für Zellen innerhalb der

digitalen Karte, welche sich außerhalb des Beobachtungsbereiches der Sensorik befinden, da in diesem Falle keine korrigierenden Messinformationen berücksichtigt werden können. Um diesen Tatsachen gerecht zu werden, wird ein künstlicher Alterungsprozess in die Karte eingeführt. Mit jeder ausgeführten Datenfusion zwischen farb- und gradientenbasierter Befahrbarkeitsaussage erfolgt eine inkrementelle Erhöhung der Unsicherheit $m_{z(i,j)}^{grad/farb}[K]$ um den Wert κ für alle Zellen, die keiner Aktualisierung gemäß der Gleichungen (7.43) bzw. (7.44) unterzogen wurden. Es ergibt sich

$$\begin{aligned}
 m_{z(i,j)}^{grad/farb}[K] &= m_{z(i,j)}^{grad/farb}[K] + \kappa, \\
 \gamma &= m_{z(i,j)}^{grad/farb}[B] + m_{z(i,j)}^{grad/farb}[U] + m_{z(i,j)}^{grad/farb}[K], \\
 m_{z(i,j)}^{grad/farb}[B] &= \frac{m_{z(i,j)}^{grad/farb}[B]}{\gamma} \\
 m_{z(i,j)}^{grad/farb}[U] &= \frac{m_{z(i,j)}^{grad/farb}[U]}{\gamma} \quad \text{und} \\
 m_{z(i,j)}^{grad/farb}[K] &= \frac{m_{z(i,j)}^{grad/farb}[K]}{\gamma}.
 \end{aligned} \tag{7.48}$$

Die Normierung mit dem Wert γ sorgt dafür, dass am Ende des Alterungsprozesses die Summe der drei Massen wieder exakt gleich Eins ist und somit eine gültige Dempster-Shafer Massenverteilung bewahrt wird.

8 Evaluation und praktische Ergebnisse

Das im Rahmen dieser Arbeit entwickelte Fahrzeugsystem wurde umfangreichen Tests unterzogen, um eine zuverlässige und sichere Funktionalität für die Teilnahme am Urban Challenge Wettbewerb sicherzustellen. Auf Basis von Simulationen [9] wurde parallel zur Fahrzeugentwicklung vor allem das prinzipielle syntaktische Verhalten der Module zur direkten Fahrzeugsteuerung überprüft. Es ist jedoch eine grundlegende Erfahrung aus der Wettbewerbsteilnahme, dass aufgrund der Komplexität und Situationsvielfalt des urbanen Umfelds sowie der engen Verzahnung aller Funktionsmodule untereinander Simulationen die umfangreiche praktische Erprobung in Form von Fahrversuchen nicht ersetzen können. Die Erprobungen wurden auf verschiedenen Testarealen in Deutschland (Abb. 8.1a bzw. 8.1b¹) sowie den Vereinigten Staaten (Abb. 8.1c) durchgeführt.



(a) Kaserne Heinrich der Löwe



(b) Verkehrsübungsplatz Waggum



(c) South West Research Institute

Abb. 8.1: Erprobungsgelände Team CarOLO

¹Quelle: Google Earth

Trotz des hohen logistischen Aufwandes erwies sich der Wechsel der Testgelände rückblickend als großer Vorteil und hat in entscheidendem Maße zum Erfolg des Gesamtsystems beigetragen. Zum einen konnten Erfahrungen in der landestypischen Umgebung mit den damit verbundenen Besonderheiten aufgebaut werden, zum anderen wurden zu ortsspezifische Systemparametrierungen rechtzeitig offensichtlich. Dies erleichterte die Bestimmung einer möglichst universellen Parametrierung, da die genauen Gegebenheiten am Wettbewerbsort im Vorfeld nicht bekannt waren. Insbesondere das Testgelände in den Vereinigten Staaten ermöglichte zudem ein Testen unter realen Verkehrsbedingungen in einem städtischen Umfeld.

In den folgenden Abschnitten sollen einige Ergebnisse der praktischen Erprobung exemplarisch vorgestellt werden. Es erfolgt zunächst in den Abschnitten 8.1 und 8.2 eine Evaluation des hybriden Umfeldmodells. In Abschnitt 8.3 folgt eine Analyse des finalen Wettbewerbsverlaufs sowie der hierbei offenbarten Stärken und Schwächen des entwickelten Fahrzeugs.

8.1 Objekt-Tracking

Die quantitativ eindeutige und reproduzierbare Beurteilung der maschinellen Umfeldwahrnehmung erweist sich als große Herausforderung, da im komplexen urbanen Umfeld eindeutige Vergleichsdaten (sog. Ground Truth Daten) nicht oder nur eingeschränkt zur Verfügung stehen. Dies gilt insbesondere für die Erfassung komplexer Hindernisse (Infrastruktur) im Randbereich. Das Erzeugen zuverlässiger Referenzdaten würde in diesem Fall eine hochgenaue Vermessung jedweder Objekte im Fahrzeugumfeld erfordern. Für bewegte Objekte ist zudem eine Online-Positionserfassung und Übermittlung in hoher Güte notwendig. Die hierfür notwendige Referenzsensorik ist entsprechend kostenintensiv und steht leider nicht zur Verfügung. Um dennoch eine qualitative und eingeschränkt quantitative Beurteilung der urbanen Objektverfolgung zu ermöglichen, wird auf alternative Bewertungsmethoden zurückgegriffen.

Hierzu werden bei stehendem Ego-Fahrzeug drei Szenarien betrachtet, die verschiedene Bewegungsmuster realer Ziele im Fahrzeugumfeld nachempfinden. Ein zusätzliches, von Menschenhand gesteuertes Testfahrzeug kommt zum Einsatz, das sich

- geradlinig gleichförmig bewegt,
- geradlinig beschleunigt und
- in Schlangenlinien gleichförmig bewegt

dem Versuchsträger nähert. Die Fahrmanöver wurden hierbei bewusst extrem (Längs- / Querb beschleunigung) ausgeführt, um neben dem prinzipiellen Verlauf der nicht direkt messbaren Schätzgrößen (Geschwindigkeit, Kurswinkel, Beschleunigung, Gierrate) die Stabilität der Algorithmen im realen urbanen Umfeld zu beurteilen.

8.1.1 Szenario 1: Geradlinige Fahrt mit konstanter Geschwindigkeit

Zunächst wird das Verhalten der Tracking-Algorithmen für den Fall einer gleichförmigen Bewegung mit konstanter Geschwindigkeit betrachtet (vgl. Abb. 8.2). Die Geschwindigkeit



Abb. 8.2: Versuchsaufbau für Szenario 1

des Testfahrzeugs während der gleichförmigen Bewegung beträgt ca. $10 \frac{m}{s}$. Es erfolgt eine Fahrt in West-Ostrichtung entlang der X-Achse des Weltkoordinatensystems. Das Ziel wird bereits vor Beginn des Fahrmanövers durch das Sensorsystem erfasst. In Abb. 8.3a ist der Verlauf der X-Position in Weltkoordinaten dargestellt, hierbei wird die Position des Objekt-Centroiden gemäß Kapitel 6.4 betrachtet. Nach ca. 2 Sekunden beginnt eine kurze Beschleunigung auf die Endgeschwindigkeit. In den Abbildungen 8.3b und 8.4a ist der Verlauf der vom Tracking-System ermittelten Geschwindigkeit sowie des Kurswinkels dargestellt. Im Stillstand ist erwartungsgemäß keine Aussage über den Kurswinkel möglich, da dieser über die Bewegungsschätzung im Kalmanfilter abgeleitet wird und ohne Objektbewegung vom Messrauschen dominiert wird. Mit Aufnahme der Objektbewegung konvergiert der Kurswinkel schnell auf dessen wahren Wert von 0° (Fahrt entlang der X-Achse). Der Schätzwert der Objektgeschwindigkeit liegt im erwarteten Bereich von ca. $10 \frac{m}{s}$. In Abb. 8.4b ist der Verlauf der geschätzten Objektbeschleunigung dargestellt. Diese bildet den Beschleunigungsvorgang zu Beginn des Manövers korrekt ab und geht dann nach einem kurzen Einschwingvorgang korrekt auf einen Wert nahe Null zurück. Das Ziel wird über den gesamten betrachteten Zeitraum durchgängig erfasst. Die erreichte Schätzgüte liegt in dem Bereich, der durch die in Kapitel 6.4 angestellten Simulationen erwartet werden kann.




Abb. 8.3: Verlauf von Position und Geschwindigkeit in Szenario 1




Abb. 8.4: Verlauf von Kurswinkel und Beschleunigung in Szenario 1

8.1.2 Szenario 2: Geradlinige Fahrt mit konstanter Beschleunigung

Im zweiten Testlauf wird die gleichförmige Bewegung durch einen abrupten Beschleunigungswechsel von maximaler Beschleunigung auf einen harten Bremsvorgang ersetzt (vgl. Abb. 8.5). Das Versuchsfahrzeug erreicht am Ende des Beschleunigungsvorgangs eine Endge-



Abb. 8.5: Versuchsaufbau für Szenario 2

schwindigkeit von ca. $22 \frac{m}{s}$. Der schnelle Beschleunigungswechsel beim Übergang zum Bremsmanöver ist im verwendeten Bewegungsmodell nicht vorgesehen und stellt daher erhöhte Ansprüche an die Robustheit des Algorithmus. In Abb. 8.6a ist der Verlauf der X-Position des Objekt-Centroiden über der Zeit dargestellt. Es zeigt sich, dass eine robuste Zielverfolgung ohne Aussetzer möglich ist. Der Verlauf der geschätzten Objektgeschwindigkeit in Abb. 8.6b gibt den Manöverwechsel wieder. Nach begonnener Objektbewegung schwingt der




Abb. 8.6: Verlauf von Position und Geschwindigkeit in Szenario 2

Kurswinkel schnell auf dem wahren Wert von ca. 0 Grad ein (Abb. 8.7a). Der Verlauf der Beschleunigung in Abb. 8.7b verhält sich gemäß den Erwartungen. Am Ende des Manövers

führt ein leichter Überschwinger des Schätzfilters zu einem Vorzeichenwechsel der Objektgeschwindigkeit und somit zu einem Sprung im Kurswinkel bzw. der Objektbeschleunigung.




Abb. 8.7: Verlauf von Kurswinkel und Beschleunigung in Szenario 2

8.1.3 Szenario 3: Fahrt in Schlangenlinien

Eine weitere Steigerung des Anspruches für die Zielverfolgung lässt sich erreichen, wenn anstelle der gleichförmigen Bewegung ein schneller Kurvenwechsel vom Zielobjekt ausgeführt wird (vgl. Abb. 8.8). Dieser sorgt für einen in etwa sinusförmigen Ist-Verlauf von Kurswinkel




Abb. 8.8: Versuchsaufbau für Szenario 3

und Kurswinkelgeschwindigkeit und kann daher vom Bewegungsmodell unter der Annahme einer konstanten Kurswinkelgeschwindigkeit nur näherungsweise dargestellt werden. In Abb. 8.9a und 8.9b ist der Verlauf der geschätzten X- und Y-Position des Ziels dargestellt. Der Verlauf der Y-Position des Objekt-Centroiden wird durch leichte Sprünge gestört. Dies




Abb. 8.9: Positionsverlauf in Szenario 3

begründet sich im Perspektivwechsel des Objekts zum Sensorsystem während der Kurvenwechsel. Durch die Wedelbewegungen wird nicht konstant der gleiche Konturbereich des Objektes durch das Sensorsystem erfasst. Wie auf Basis der Simulationen in Abschnitt 6.4.3 zu erwarten ist, wirken sich diese Sprünge des Bezugspunktes negativ auf die Schätzung der




Abb. 8.10: Geschätzte Geschwindigkeit und Beschleunigung in Szenario 3

Objektgeschwindigkeit und -beschleunigung aus, deren Verlauf in Abb. 8.10a und 8.10b dargestellt ist. Dennoch ist eine robuste Zielverfolgung möglich. Es kommt zu keinem Abriss der Objektverfolgung mit anschließender Neuinitialisierung des Zieles. Der Verlauf des Kurswinkels (Abb. 8.11a) sowie der Kurswinkelgeschwindigkeit (Abb. 8.11b) weist den erwarteten sinusförmigen Charakter auf.




Abb. 8.11: Geschätzter Kurswinkel und Kurswinkelgeschwindigkeit in Szenario 3

8.2 Fahrbereichsanalyse

Analog zur Vorgehensweise bei der Betrachtung der urbanen Objektverfolgung soll die Leistungsfähigkeit der kartenbasierten Fahrbereichsanalyse an drei Beispielszenarien demonstriert werden. Diese decken eine Reihe von typischen Kombinationen aus vertikalem Höhenprofil und farbbasierter Abgrenzung des Randbereiches ab.

8.2.1 Szenario 1: Begrenzung durch Bordstein / Grünstreifen

In Abb. 8.12 wird der Fahrbahnrand auf der rechten und linken Seite durch den Grünstreifen sowie einen flachen Unterschied im Höhenprofil begrenzt. Die aus Verbundsteinpflaster zusammengesetzte Fahrbahnoberfläche hebt sich deutlich vom Randbereich ab und bietet so ideale Bedingungen für die farbbasierte Klassifikation.



Abb. 8.12: Testumgebung Szenario 1

In den Abbildungen 8.13a und 8.13b sind die Eingangsdaten der kartenbasierten Befahrbarkeitsanalyse in dieser Umgebung dargestellt. Der gewählte Kartenausschnitt in Abb. 8.13a umfasst ein Areal von 200×200 Gitterzellen, was einer Fläche von 40×40 Metern entspricht. Das eigene Fahrzeug befindet sich in der Mitte des Ausschnitts. Bereits in der Höhenkarte des Umfelds in Abb. 8.13a lässt sich deutlich der Straßenverlauf vom Randbereich unterscheiden. Hierbei ist der Grauwert linear mit dem Höhenmesswert skaliert, so dass sich Höhen oberhalb der Fahrbahnebene hell vom Hintergrund abheben.

Die farbbasierte Klassifikation in Abb. 8.13b liefert zuverlässige Eingangsdaten in weiten




Abb. 8.13: Eingangsdaten Szenario 1

Bildbereichen, jedoch nimmt ihre Güte zum Bildrand hin ab, was auf die ungünstige Beleuchtungssituation zurückzuführen ist. Die gelbe Fahrspurmarkierung in der Mitte des Straßenverlaufs hebt sich zwar vom charakteristischen Farbprofil des Untergrunds ab, wird aber durch Anwendung der in Abschnitt 7.4 beschriebenen Farbfiler als ungültig eingestuft (rote Markierung). In den Abbildungen Abb. 8.14a und 8.14b ist die resultierende Gradienten-





Abb. 8.14: Zwischendaten Szenario 1

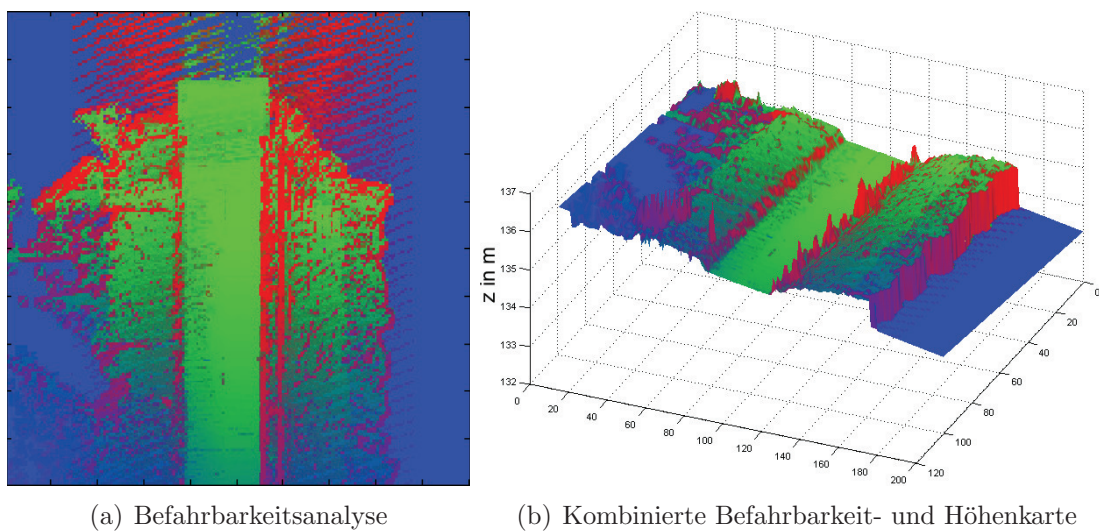
karte sowie die Projektion der farbbasierten Klassifikation auf die Karte dargestellt. Beide ermöglichen eine klare Abgrenzung von Fahrbahn und Randbereich. Über Anwendung der probabilistischen Sensormodelle sowie deren zeitlicher Integration in der Karte ergeben sich die in den Abbildungen 8.15a und 8.15b dargestellten Befahrbarkeitsaussagen. Die Dempster-Shafer Massenverteilung wurde hierbei in die Farbwerte rot (unbefahrbar), grün (befahrbar) und blau (unbekannt) kodiert.



(a) Befahrbarkeit Gradient (b) Befahrbarkeit Farbklassifikation

Abb. 8.15: Befahrbarkeit Szenario 1

Die Qualität der Einzelaussagen lässt sich durch die Fusion der Darstellungen weiter steigern. In den Abbildungen 8.16a und 8.16b ist das Ergebnis der fusionierten Befahrbarkeit sowie dessen Projektion auf die Höhenkarte der Fahrzeugumgebung dargestellt. Insbesondere die



(a) Befahrbarkeitsanalyse (b) Kombinierte Befahrbarkeit- und Höhenkarte

Abb. 8.16: Ergebnisse Datenfusion

Übergangsbereiche zum Randbereich werden durch die Kombination von Gradienten- und Farbinformation stabilisiert, so dass eine zuverlässige Fahrzeug-Querführung möglich ist. Der Einfluss vereinzelter Fehlklassifikationen in der farbbasierten Darstellung oder Messausreißern im Höhenfeld wird minimiert. Der im unteren Bildbereich zunehmende Blauanteil ist durch die in Abschnitt 7.6 eingeführte Alterungsfunktion im kartenbasierten Modell zu erklären.


8.2.2 Szenario 2: Begrenzung durch Randbebauung / Böschung

In Abb. 8.17 ist die Fahrzeugumgebung im Falle des zweiten Testszenarios dargestellt. Die Fahrbahn ist auf der rechten und linken Seite von Randbebauung bzw. einer deutlichen Böschungskante begrenzt. Dieser Höhenunterschied lässt sich in der Höhenkarte aus Abb.



Abb. 8.17: Szenario 2

8.18a klar erkennen, so dass optimale Bedingungen für eine Befahrbarkeitsabschätzung auf Basis der Höhendaten bestehen. Betrachtet man Farbe und Textur der Fahrbahnoberfläche



(a) Höhenfeld

(b) Eingang Farbklassifikation

Abb. 8.18: Eingangsdaten Szenario 2

so fällt auf, dass diese durch eine Reihe von Verschmutzungen belegt ist. Erwartungsgemäß führt dies zu Beeinträchtigungen bei der farbbasierten Segmentierung der Fahrbahn, wie in Abb. 8.18b zu erkennen ist.

Überführt man die Höhenkarte in ihre Gradientendarstellung in Abb. 8.19a, so lässt sich der Fahrbahnrand klar erkennen. In Abb. 8.19b ist parallel dazu die Projektion der farbbasierten Klassifikation auf die Kartenebene dargestellt. Die Anwendung der probabilistischen Sensor-

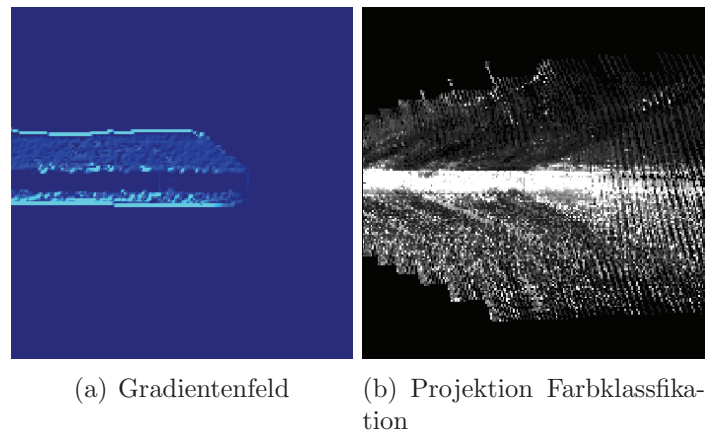


Abb. 8.19: Zwischendaten Szenario 2

modelle auf die beiden Darstellungen sowie deren zeitliche Integration in der Karte führen zu den in den Abbildungen 8.20a bzw. 8.20b dargestellten Befahrbarkeitsaussagen. Deren Fusi-

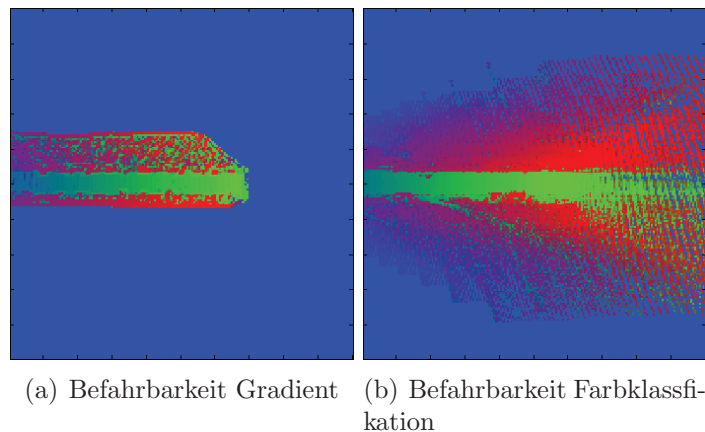


Abb. 8.20: Befahrbarkeit Szenario 2

on in den Abbildungen 8.21a bzw. 8.21b sorgt für eine Optimierung der Gesamtaussage. Die resultierende Befahrbarkeitsaussage ermöglicht eine sichere Fahrzeug-Querführung entlang des vergleichsweise schmalen Korridors in der betrachteten Szene.

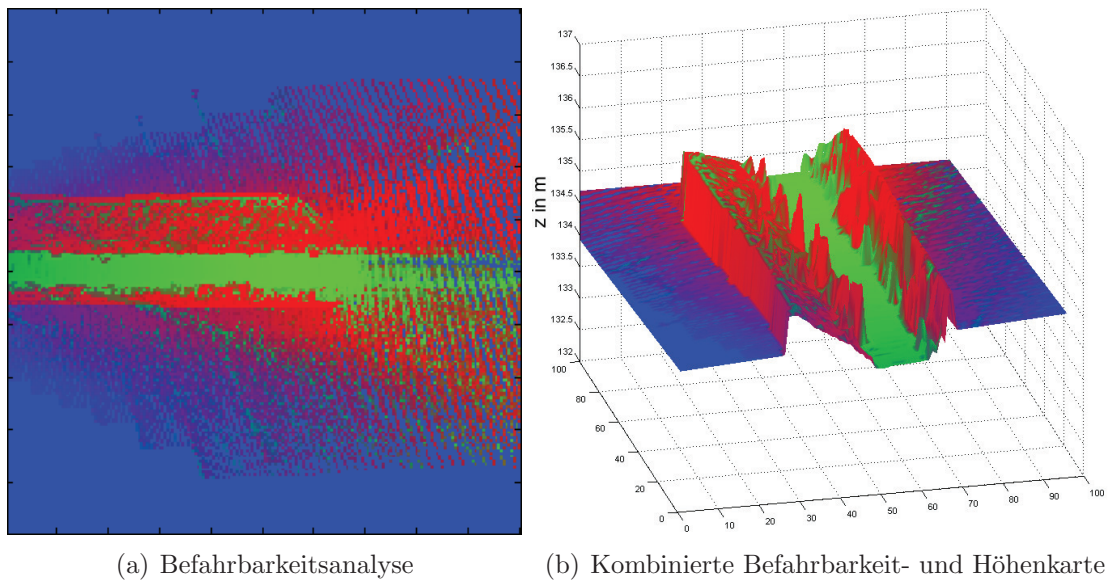


Abb. 8.21: Ergebnisse Datenfusion

8.2.3 Szenario 3: Rampe

Die Anforderungen an das Umfeldmodell werden komplexer, wenn anstelle eines flachen Umfeldes die Fahrzeugführung in Anwesenheit von Gefälleunterschieden realisiert werden soll. Um diesen Einfluss zu untersuchen, wurde im letzten Testszenario das Durchfahren einer flach abfallenden Rampe untersucht (vgl. Abb. 8.22). Das vertikale Höhenprofil der Fahrbahnober-



Abb. 8.22: Szenario 3

fläche setzt sich zusammen aus dem Gefälle der Rampe sowie den begrenzenden Strukturen im Randbereich (Böschung bzw. Strauchwerk). Das Eintragen der Abstandsmessdaten in das kartenbasierte Umfeldmodell führt zu der in Abb. 8.23a dargestellten Höhenkarte, welche die Neigung der Rampe bezüglich des erdfesten Koordinatensystems deutlich wiedergibt.

Es zeigt sich des Weiteren ein Vorteil der in Abschnitt 7.3.3 beschriebenen globalen Approximation einer frei orientierbaren Fahrbahnebene. Diese kann die Neigung der Rampe bei der Interpolation fehlender Höhenmesswerte berücksichtigen.




Abb. 8.23: Eingangsdaten Szenario 3

Zahlreiche Verschmutzungen auf der Fahrbahnoberfläche erschweren die farbbasierte Befahrbarkeitsabschätzung. Dies drückt sich in der Vielzahl von Bereichen mit niedriger Befahrbarkeit in Abb. 8.23b aus, sodass auf Basis eines einzelnen Messzyklus eine Abschätzung des Straßenverlaufs nahezu unmöglich ist.

Die Neigung der Rampe geht im unteren Bereich bis an die Grenze des noch als befahrbar einzustufenden Gradienten. In Abb. 8.24a und 8.24b ist die erzeugte Gradientenkarte sowie die Projektion der farbbasierten Klassifikation auf die Karte dargestellt. In der aus den Zwischen-

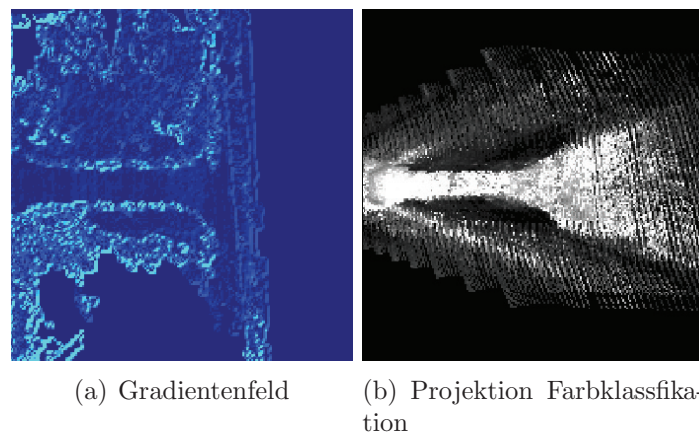


Abb. 8.24: Zwischendaten Szenario 3

größen abgeleiteten probabilistischen Befahrbarkeitsaussage fällt auf, dass über die zeitliche Integration mehrerer Messungen insbesondere für die farbbasierte Klassifikation (vgl. Abb. 8.25b) eine stabilere Aussage erzielt wird als bei alleiniger Betrachtung eines Eingangsbildes.

Die starke Neigung der Rampe im unteren Abschnitt führt über die Parametrierung des Sensormodells zu einem Gebiet mit hoher Unsicherheit im Zentrum von Abb. 8.25a. Das System ist sich über die Befahrbarkeit entsprechend unsicher. Diese Unsicherheit kann jedoch durch




Abb. 8.25: Befahrbarkeit Szenario 3

Kombination beider Aussagen weitgehend minimiert werden, so dass sich für die fusionierte Darstellung in Abb. 8.26a bzw. 8.26b ein konsistentes Gesamtbild ergibt. Im automatischen Fahrbetrieb wird so ein sicheres Durchfahren der Rampe ermöglicht.

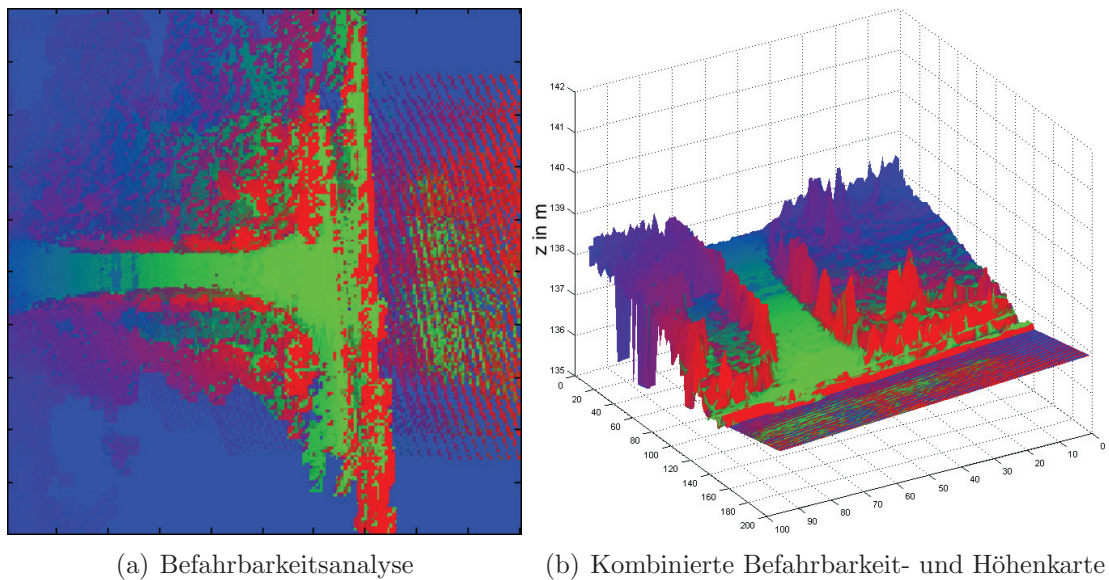


Abb. 8.26: Ergebnisse Datenfusion

8.3 Wettbewerbsverlauf

Die Leistungsfähigkeit der hier vorgestellten autonomen Fahrzeugplattform soll auf Basis der im Wettbewerb erzielten Ergebnisse diskutiert werden. Dies ermöglicht insbesondere die Bewertung des komplexen Zusammenspiels aller Fahrzeugmodule, welche erst in ihrer Gesamtheit zur Bewältigung der innerstädtischen Fahraufgabe in der Lage sind. Das hier behandelte Versuchsfahrzeug konnte sich in einem ursprünglich über 100 internationale Teilnehmer umfassenden Gesamtfeld für das Finale der besten 11 Teams qualifizieren und somit auf Augenhöhe mit den ebenfalls antretenden internationalen Spitzenuniversitäten agieren. Auch wenn der Gesamtsieg nicht erstritten wurde, ließen sich alle Ziele des Teams sowie der Sponsoren mehr als erfüllen und somit die Grundlagen für eine weitergehende Forschung auf dem Gebiet der autonomen mobilen Systeme legen. Unabhängig von dem Erfolg im Wettbewerb kann man das größte Lernpotential jedoch aus den kleinen und großen Schwierigkeiten im Verlauf des praktischen Einsatzes gewinnen. Um dies zu ermöglichen, sollen die Erfahrungen der Final- und Halbfinalteilnahme an dieser Stelle detailliert erläutert werden.

8.3.1 Halbfinale

Der Urban Challenge Wettbewerb vom 26. Oktober bis zum 3. November 2007 gliederte sich in eine Reihe von Qualifikationsläufen sowie den eigentlichen Finallauf. Im Rahmen des Halbfinals galt es, sich in einem Teilnehmerfeld von 35 Teams für einen der Finalplätze zu qualifizieren, wofür die wichtigsten Funktionalitäten der Versuchsträger demonstriert werden mussten. Als Austragungsort für die Läufe wurde vom Veranstalter ein stillgelegtes Militärgelände (George Air Force Base - Victorville, CA) im Westen der Vereinigten Staaten zur Verfügung gestellt. In insgesamt drei Qualifikationsläufen (A bis C) wurden unterschiedliche Teilaspekte der Wettbewerbsteilnehmer analysiert (vgl. Abb. 8.27).

Neben der Grundfunktionalität stand vor allem die Sicherheit und Zuverlässigkeit der Fahrzeuge im Fokus der Wettbewerbsleitung, die einen ähnlichen Ausgang wie beim ersten Grand Challenge Wettbewerb im Jahre 2004 (kein Team erreichte damals das Ziel) vermeiden wollte.

8.3.2 Qualifikationslauf A: Interaktion mit Fließverkehr

Im Rahmen des ersten Testlaufes wurde die Fähigkeit zur autonomen Interaktion mit fließendem Verkehr geprüft. Es galt hierbei, zwei Linksabbiege-Manöver in einem bestehenden

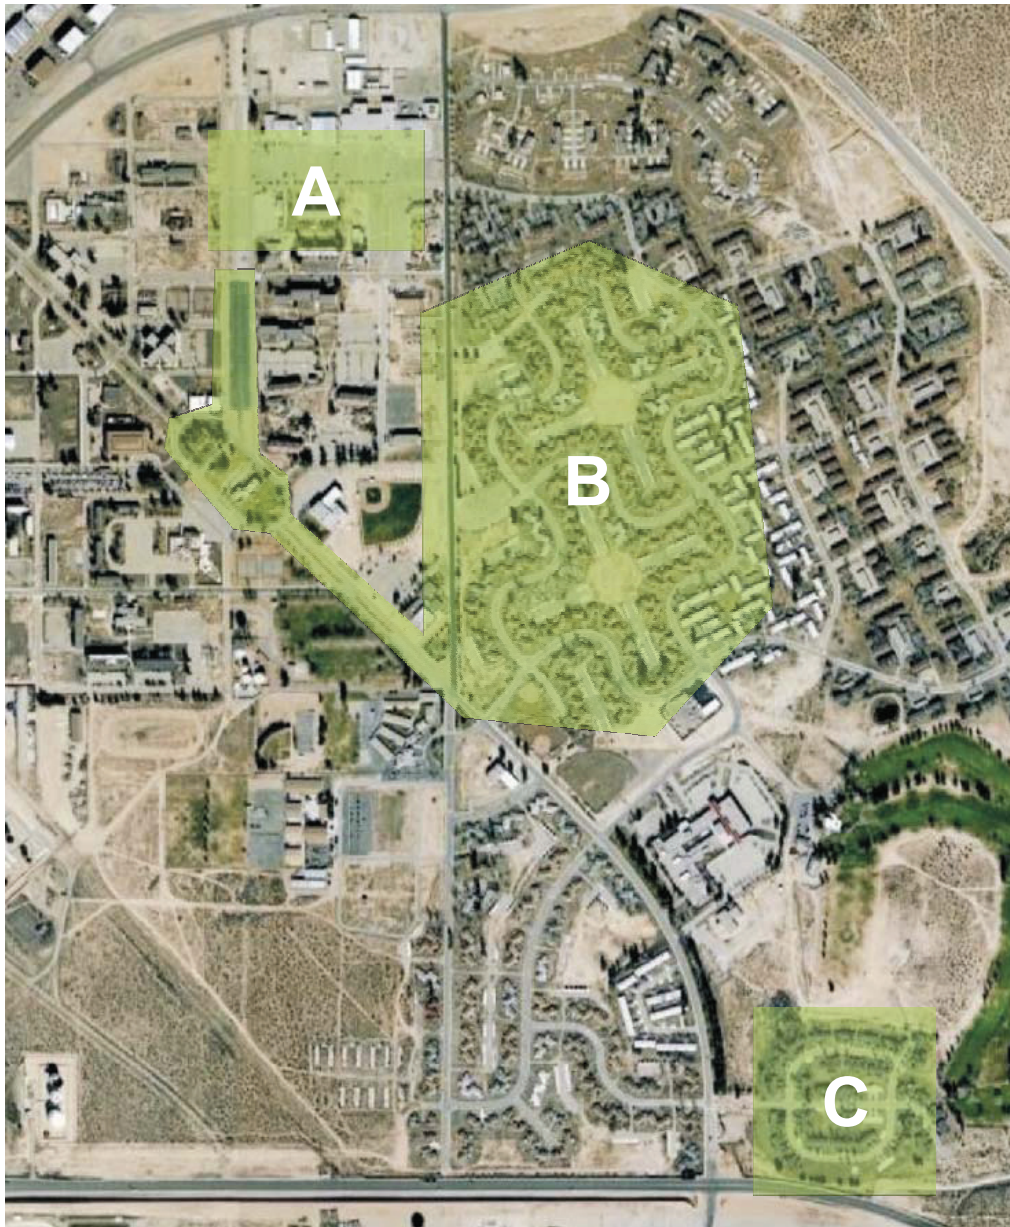


Abb. 8.27: Halbfinal-Testareale Urban Challenge 2007

Verkehrsfluss dergestalt auszuführen, dass weder eine Gefährdung noch eine Behinderung der übrigen Verkehrsteilnehmer durch das autonome Fahrzeug verursacht wurde. Als Testparcours wurde eine ehemalige Parkfläche umfunktioniert, welche durch einen Rundkurs umfahren werden konnte (vgl. Abb. 8.28). In beiden Fahrtrichtungen befanden sich neben dem autonomen Fahrzeug noch eine Reihe zusätzlicher Fahrzeuge, welche von Menschenhand gesteuert wurden. Für den Abbiegevorgang musste eine ausreichend große Zeitlücke zwischen den Fahrzeugen abgepasst werden. Rückblickend erwies sich insbesondere dieser Qualifika-




Abb. 8.28: Qualifikationslauf A

tionslauf als größte Hürde für die teilnehmenden Fahrzeuge. Dies lag neben dem vergleichsweise dichten simulierten Verkehrsfluss auch an den geringen Ausdehnungen des Parcours mit entsprechend engen Kurvenradien. Der Querabstand zu den Absperrvorrichtungen am Streckenrand war teilweise so gering, dass die in den Wettbewerbsbedingungen vorgegebenen Sicherheits-Mindestabstände für stationäre Objekte unterschritten wurden (vgl. Abb. 8.29). Dies stellte die automatisierte Bahnplanung für eine Reihe von Teilnehmern vor entsprechen-



Abb. 8.29: Absperrungen in Qualifikationslauf A

de Herausforderungen. Die größte Hürde für unser Versuchsfahrzeug ergab sich jedoch durch die (Teil-)Verdeckung des Sensor-Sichtbereiches, welche von den vorbeifahrenden Fahrzeugen verursacht wurde (vgl. Abb. 8.30). Der durch die Verdeckung resultierende Totbereich im Sichtfeld erschwerte die Bestimmung der Zeitlücken, ein zu zögerliches Abbiegeverhalten wurde jedoch vom Veranstalter nicht akzeptiert. Ursächlich war hier vor allem der gerin-




Abb. 8.30: Herausforderung in Qualifikationslauf A

ge vertikale Öffnungswinkel der Laserscanner in Verbindung mit deren Verbauposition auf Höhe des Stoßfängers. Der Einsatz von dachmontierten LIDAR-Systemen mit großem vertikalem Öffnungswinkel, wie von anderen Wettbewerbsteilnehmern umgesetzt [119, 124], hätte hier einen entscheidenden Vorteil bedeutet - die Hardware stand jedoch im Rahmen dieser Arbeit nicht zur Verfügung. Um eine sichere Fahrzeugführung zu gewährleisten, musste anstelle dessen im Fahrentscheider ein Mittelweg zwischen freiem Sichtfeld und unnötig großer Verzögerung beim Abbiegevorgang erreicht werden, was einige Iterationen erforderte.

8.3.3 Qualifikationslauf B: Grundlegende Navigation, Parken und Freifahrtzonen

Der zweite Qualifikationslauf bestand im Wesentlichen aus einer ausgedehnten Navigationsfahrt im urbanen Straßennetz. Der in Abb. 8.31 dargestellte Parcours setzte sich zusammen aus einer Reihe von Kreuzungen und Engstellen im ehemaligen Wohnbereich des Militärgeländes. Besondere Herausforderungen ergaben sich bereits in der Startphase beim Verlassen des Boxenbereiches (vgl. Abb. 8.32a), dessen Ausfahrt sich durch diverse Abspermaßnahmen vergleichsweise eng gestaltete. Die Abspermaßnahmen wurden einigen Fahrzeugen früh zum Verhängnis (vgl. Abb. 8.32b), andere Teilnehmer waren nicht in der Lage, einen gültigen Pfad aus der Startzone heraus zu finden und blieben schlichtweg stehen. Obwohl die Ergebnisse der Mitbewerber einigen Anlass zur Sorge gaben, konnte das hier behandelte

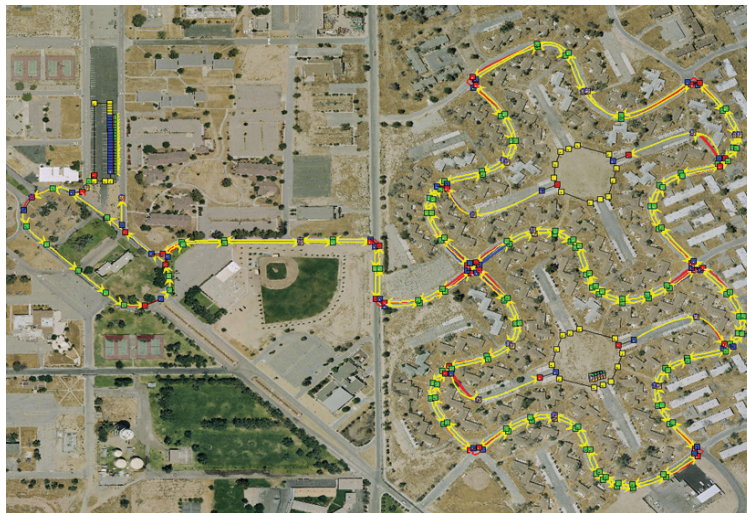


Abb. 8.31: Qualifikationslauf B



(a) Startbereich Qualifikationslauf B



(b) Mitbewerber



(c) Unser Fahrzeug

Abb. 8.32: Startzone im Qualifikationslauf B

Fahrzeug die Startzone ohne nennenswerte Probleme verlassen und erfolgreich in das Testgebiet einfahren (vgl. Abb. 8.32c). Die Flexibilität der Bahnplanung auf Basis des in Kapitel 4.3 beschriebenen Potentialfeldansatzes erwies sich an dieser Stelle als Vorteil.

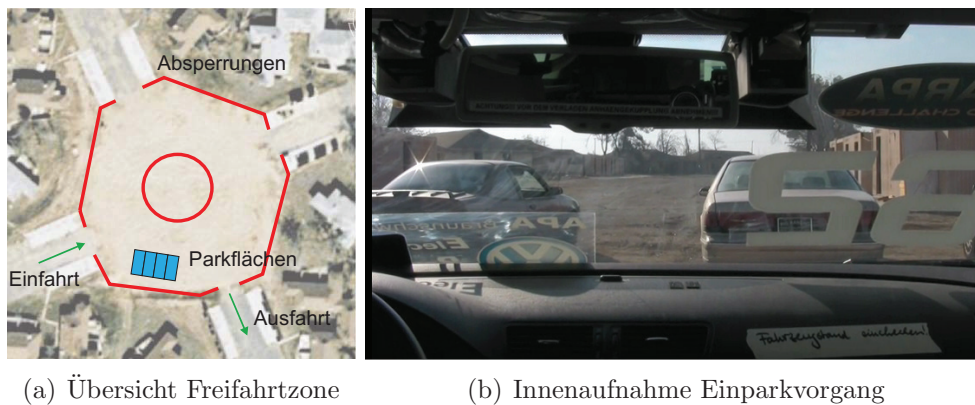
Im weiteren Verlauf wurden Umfeldwahrnehmung und Bahnplanung durch eine Reihe von Engstellen auf die Probe gestellt. Am Fahrbahnrand wurden diverse Hindernisse positioniert (vgl. Abb. 8.33), welche durch einen Eingriff in die Querführung zu umfahren waren. Das Versuchsfahrzeug meisterte diese Hürden ohne nennenswerte Beeinträchtigungen. Die in Kapitel 6 beschriebene Erweiterung der objektbasierten Hindernisdarstellung um die Freiform-Darstellung zur Modellierung beliebiger Hinderniskonturen sowie die kartenbasierte Fahrbereichsanalyse erwiesen sich an dieser Stelle als besonders nützlich. Eine weitere Her-



Abb. 8.33: Innenaufnahme Überholvorgänge und Engstellen im Qualifikationslauf B

ausforderung war die Navigation und das automatische Einparken innerhalb sog. Freifahrtzonen. Diese wurden durch kreisförmige Freiflächen definiert, für die bis auf einen definierten Ein- und Ausfahrpunkt kein vorgegebenes Straßennetz wie im restlichen Parcours bestand. Das Zentrum der Freiflächen wurde zudem durch Absperrmaßnahmen blockiert (vgl. Abb. 8.34a), die Ein- und Ausfahrt wurde durch ein Tor dargestellt. Das Versuchsfahrzeug erfüllte alle Aufgaben inklusive des automatischen Einparkvorgangs (vgl. Abb. 8.34b) und konnte als eines von lediglich drei Fahrzeugen im Feld den zweiten Qualifikationslauf bereits im ersten Versuch bestehen.

Kleinere Probleme traten bei der Ausfahrt aus den Freifahrtzonen auf. Der verhaltensbasierte Bahnplaner war nicht zu jedem Zeitpunkt in der Lage, eine geschlossene Ausfahrtrajektorie zu ermitteln. Durch den begrenzten Planungshorizont ergaben sich ungünstige Sackgassen-Situationen, welche durch zusätzliche Rangiermanöver aufgelöst werden mussten. Das gezeigte Verhalten brachte dem Versuchsträger einmal mehr den Ruf einer gewissen Kreativität ein. Dieses ist jedoch charakteristisch für den gewählten Ansatz der Bahnplanung nach der Potentialfeldmethode, welche anfällig für ein unerwünschtes Aufsuchen lokaler Minima im Konfigurationsraum des Roboters ist.



(a) Übersicht Freifahrtzone

(b) Innenaufnahme Einparkvorgang

Abb. 8.34: Freifahrtzonen im Qualifikationslauf B

8.3.4 Qualifikationslauf C

Im letzten der drei Qualifikationsläufe galt es, klassische Kreuzungssituationen nach amerikanischem Recht (4-way-stop) zu bestehen. Hierbei sind die Fahrzeuge in der Reihenfolge ihres Eintreffens vorfahrtsberechtigt, was eine entsprechende Leistungsfähigkeit der Wahrnehmungsmodule erfordert. Im weiteren Verlauf des Parcours musste zudem mit Straßenblockaden gerechnet werden. Diese mussten erkannt und vom Fahrzeug durch Wenden und die Berechnung einer alternativen Route zum Ziel behandelt werden. Im Verlauf der Aufgabe kam es zu keinen größeren Funktionsstörungen. Der in Abb. 8.35 gezeigte Parcours konnte fehlerfrei absolviert werden. Die Wahrnehmung im Kreuzungsbereich (vgl. Abb. 8.36a) erwies sich




Abb. 8.35: Übersicht Qualifikationslauf C

hierbei als hinreichend robust. Als besondere Herausforderung musste eine Straßenblockade

per Schlagbaum erkannt werden (vgl. Abb. 8.36b). Die auf Höhe der Frontscheibe montierte Schranke stellte aufgrund des geringen Zielquerschnitts sowie des fehlenden Bodenkontaktes erhöhte Ansprüche an die Umfeldwahrnehmung und wurde einigen Wettbewerbsteilnehmern zum Verhängnis. Trotz begründeter Bedenken (das Ziel befand sich oberhalb des Sichtbereiches der LIDAR-Sensorik) konnte unser Fahrzeug die Situation ohne Zwischenfälle meistern. Maßgeblich für den Erfolg verantwortlich war an dieser Stelle die Datenfusion mit dem 24 GHz Nahbereichsradar, da dieses als einziges Sensorsystem einen ausreichend großen vertikalen Öffnungswinkel für die Erfassung der Schranke aufwies.



Abb. 8.36: Kreuzungssituation und Straßenblockade in Qualifikationslauf C

8.3.5 Finale

Durch die in den Qualifikationsläufen gezeigte Funktionalität wurde eine Finalteilnahme unter den besten 11 Teams ermöglicht. Im Verlauf des finalen Laufs am 3. November galt es, drei verschiedene Missionen mit kurzem Zwischenstop zum Nachladen der Missionsdirektiven im autonomen Fahrbetrieb zu absolvieren. Zwischen den Missionen gab es keine Gelegenheit, auf das Fahrzeug Einfluss zu nehmen. Die Missionsziele wurden erst wenige Minuten vor dem Start zur Verfügung gestellt, sodass die Fahrzeuge während des Finallaufs im Wesentlichen auf sich selbst gestellt waren. Da alle Teilnehmer gleichzeitig im Feld waren, kam es zu einer Reihe von Interaktionsmöglichkeiten zwischen autonomen Plattformen, was insofern ein Novum im Bereich der autonomen Fahrzeugführung darstellte. Zusätzliche Verkehrsteilnehmer wurden wiederum durch eine Reihe von Testfahrern gestellt, um einen realistischeren urbanen Verkehrsfluss zu simulieren. Für ein Mindestmaß an Sicherheit wurde jedes teilnehmende Fahrzeug durch ein Verfolgerfahrzeug begleitet. Dieses konnte im Notfall per Funk einen sicheren Betriebszustand (Pause oder Notaus) herbeiführen. Im Rennverlauf kam es zu einer Reihe von Pausierungen für das gesamte Feld, diese Perioden wurden von der Wettbewerbsleitung genutzt, um verunfallte Fahrzeuge zu entfernen oder Stausituationen aufzulösen.

In Abb. 8.37 ist das im Finale zur Verfügung gestellte Straßennetz dargestellt. Im Wesentlichen umfasste dieses die Areale A und B der Qualifikationsläufe, erweitert um eine zweispurige Schnellstraße im Norden und einige urbane Straßenzüge im Süden und Osten des Geländes.



Abb. 8.37: Übersicht Finale

Obwohl unser Fahrzeug letztlich nicht alle Missionen erfolgreich absolvierte und das Rennen vorzeitig beenden musste, konnte die Leistungsfähigkeit zur autonomen Navigation durch ein städtisches Szenario eindrucksvoll unter Beweis gestellt werden. Es wurden insgesamt ca. 16 km autonome Fahrtstrecke zurückgelegt, wobei 524 Wegpunkte und 13 in der Mission vorgegebene Checkpunkte erreicht wurden. Während der Fahrt wurden 65 Kreuzungen durchfahren. Insgesamt befand sich das Versuchsfahrzeug 2 Stunden und 28 Minuten im autonomen Fahrbetrieb auf der Strecke. Neben diesen quantitativen Leistungsdaten treten eine Reihe von Schlüsselsituationen aus dem Rennverlauf hervor, welche eingehend erläutert werden sollen.

- Nach dem erfolgreichen Start um 07:27 verließ das Fahrzeug die Startzone und nahm über den Kreisverkehr Kurs auf das ehemalige Wohngebiet im Süden des Geländes (vgl. Abb. 8.38a). Der Versuchsträger durchquerte das Stadtgebiet sowie einige Kreuzungen erfolgreich und näherte sich um 07:50 einer Offroad-Passage, welche das Stadtgebiet und die Schnellstraße im Norden des Geländes miteinander verband. Die Passage war stark abschüssig, die Fahrbahn unbefestigt. Unser Fahrzeug absolvierte einen großen Teil der Passage erfolgreich, bevor es auf ein abgestelltes Verfolgerfahrzeug eines vorausfahrenden Wettbewerbsteilnehmers aufief (vgl. Abb. 8.38b und 8.38c). Da der Versuchsträger von der Wettbewerbsleitung zu spät pausiert wurde, setzte er zur

Vorbeifahrt an, geriet aufgrund des schmalen und unbefestigten Fahrstreifens in den weichen, sandigen Untergrund und blieb stecken (vgl. Abb. 8.38d). Aufgrund der un-



(a) Start



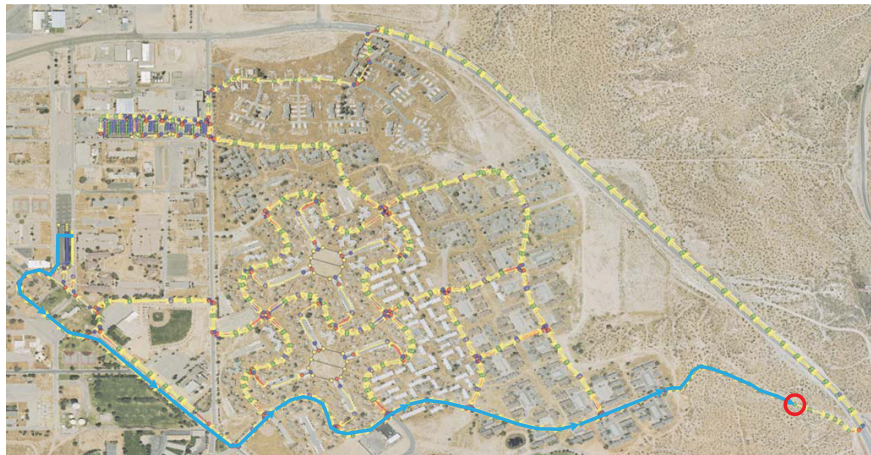
(b) Weg durch die Offroad-Passage



(c) Auflaufen auf Verfolgerfahrzeug



(d) Bergung des Versuchsträgers



(e) Wegstrecke zur Offroad-Passage

glücklichen Situation, welche bei rechtzeitiger Pausierung und ohne die Beeinflussung des Verfolgerfahrzeugs nicht zustande gekommen wäre, wurde das Fahrzeug zurück auf die Strecke gesetzt und die Wiederaufnahme des Wettbewerbs gestattet.

Rückblickend führten zwei Effekte zu diesem unerwünschten Fahrverhalten. Zum Einen wurde die Wahrnehmung des fahrbaren Bereiches beeinträchtigt, da der einfarbige sandige Untergrund eine Unterscheidung von Straße und Randbereich erschwerte und des Weiteren eine Randbebauung mit ausgeprägtem vertikalen Höhenprofil zur Fahrbereichsanalyse nicht vorlag. Zum Anderen wurde die korrekt erkannte blockierte Straße

vom Fahrentscheider falsch behandelt. Obwohl lediglich eine einspurige Fahrbahn in der Kartenbasis abgelegt war, wurde zu einem Spurwechsel mit dem Zwecke der Vorbeifahrt angesetzt. Nach der Entscheidung zum Spurwechsel bestimmte der verhaltensbasierte Fahrentscheider zwar die Route mit dem günstigsten Kostenverhältnis aus der Bewertung des Hindernisses im rechten Teil des Fahrstreifens sowie der (Un-)Befahrbarkeit auf der linken Seite, eine harte Plausibilisierung der Fahrentscheidung gegen das bekannte Streckennetz unterblieb jedoch, wodurch die Fehlentscheidung zustande kam. Die in anderen Situationen nützliche Kreativität der verhaltensbasierten Bahnplanung wurde dem Fahrzeug in dieser Situation zum Verhängnis.

- Nach Wiederaufnahme des automatischen Fahrbetriebs um 08:17 setzte das Fahrzeug die Mission fort und näherte sich über die Schnellstraße dem Stadtgebiet im Norden des Testgeländes (vgl. Abb. 8.38). Die Wiedereinfahrt in das Stadtgebiet über eine weitere weitgehend unbefestigte Straße gelang problemlos. Um 08:26 fiel einer der Rechner für die Umfeldwahrnehmung aus. Der Fehler wurde von der automatisierten Systemüberwachung erfasst, das Fahrzeug angehalten und das Rechnersystem neu gestartet, wodurch ein vorzeitiges Ausscheiden verhindert wurde. Der Wiederstart des Rechnersystems verlief erfolgreich, sodass die volle Funktionalität nach einer kurzen Wartezeit (ca. 30 Sekunden) wieder zur Verfügung stand. Die Fehlerursache blieb unklar. Um 09:00 führte ein Ausfall des Navigationssystems zu einer weiteren Zwangspause, auch dieser Fehler wurde durch die automatisierte Systemüberwachung behoben. Im weiteren Verlauf wurde ein großer Teil des Wettbewerbsgeländes fehlerfrei durchfahren. Nach einer erneuten Vorbeifahrt im Kreisverkehr am Start-/Zielbereich nahm das Fahrzeug Kurs auf das Zentrum des Wettbewerbsareals. Um 09:08 kam es zu einem Planungsfehler des Fahrentscheiders beim Behandeln der durch den roten Kreis in Abb. 8.38 dargestellten Kreuzung.



Abb. 8.38: Kursverlauf bis Planungsfehler

- Anstatt wie gewünscht links abzubiegen, fuhr der Versuchsträger geradeaus weiter und verließ somit das durch GPS-Wegpunkte vorgegebene Streckennetz. Die Missionsplanung erkannte den Fehler einige Sekunden später und nahm Kurs auf den nächsten gültigen Wegpunkt, der ca. 400 Meter südlich der Kreuzung lag. In der Zwischenzeit (rote Markierung in Abb. 8.39) war keine GPS-basierte Wegplanung mehr möglich, so dass das Fahrzeug lediglich durch das hybride karten- und objektbasierte Umfeldmodell auf der Strecke gehalten wurde. Dennoch konnte der Versuchsträger ohne Zwischenfall dem Straßenverlauf in Richtung Süden folgen und fädelt um 09:11 erfolgreich in den bekannten Kurs ein. Die Mission wurde vom nächsten bekannten Wegpunkt aus fortgesetzt. Die Route führte über einen weiten Bogen durch den innerstädtischen Parcours



Abb. 8.39: Kursverlauf ab Planungsfehler

in Richtung des Parkbereichs im Nordwesten.

- Um 09:20 missachtete das Fahrzeug die Vorfahrtsituation bei der Einfahrt in die Parkzone (roter Kreis in Abb. 8.40a) und führte eine kritische Situation mit dem Versuchsträger des Team Talos (Massachusetts Institute of Technology, MIT) herbei. Dieser befand sich auf Gegenkurs und führte seinerseits kein Ausweichmanöver aus. Die kritische Situation wurde durch rechtzeitiges Eingreifen der Verfolgerfahrzeuge abgebrochen.

Eine nachträgliche Analyse dieser Situation hat ergeben, dass die betreffende Kreuzung auf unserer Seite bei der manuellen Nachbearbeitung des Kartenmaterials falsch abgelegt wurde, wie in Abb. 8.40b dargestellt ist. Im Rahmen der Finalvorbereitung musste die Vorfahrtregelung an jeder Kreuzung von Hand durch das Setzen einiger Stoppschild-Markierungen im Kartenmaterial angepasst werden. Durch den Fehler in der Karte (fehlendes Stoppschild) konnte die Kreuzungssituation durch unser Fahrzeug nicht korrekt erkannt werden - der entgegenkommende Verkehr wurde daher als nicht vorfahrtberechtigt eingestuft.



(a) Einfahrt in den Parkbereich

(b) Kartenfehler

Abb. 8.40: Zufahrt zum Parkbereich und Fehlerursache

Nachdem der entstandene Konflikt aufgelöst wurde, konnten beide Fahrzeuge ihre Fahrt fortsetzen. Unser Versuchsträger absolvierte daraufhin erfolgreich die Navigation in der Parkzone und führte um 09:28 ein Parkmanöver durch.

- Um 09:30 setzte das Fahrzeug seinen Weg fort und durchfuhr einen großen Teil des zur Verfügung stehenden Streckennetzes im Stadtbereich ohne nennenswerte Vorfälle (vgl. Abb. 8.41a). Um 09:46 passierte es erneut den Kreisverkehr im Start-/Zielbereich. Im Anschluss daran nahm der Versuchsträger Kurs auf die Freifahrtzone im Zentrum des Wettbewerbsgeländes. Um 09:52 wurde die Freifahrtzone erreicht und das Fahrzeug begann mit der Durchfahrt. Im Verlauf der Freifahrtzone ließ sich in den Statusdateien des Fahrzeug eine Häufung verschiedener Fehlerzustände beobachten. Zum einen wurde der Prozess zur Bahnplanung und Fahrentscheidungsfindung durch die automatisierte Systemüberwachung mehrfach neu gestartet, da dieser die maximal zulässige Zykluszeit überschritt. Im Zuge der Neustarts wurde auch die Mission mehrfach neu gestartet, wodurch die Bahnplanung aus der Interrupt-Routine für die Behandlung der Freifahrtzone zurück in den normalen Fahrbetrieb fiel. Das Fahrzeug nahm daraufhin Kurs auf den nächsten bekannten Wegpunkt. Es vermied zwar die Kollision mit den Absperreinrichtungen am Rand der Freifahrtzone, jedoch wurden eine Reihe von Rangiermanövern bei der Suche nach dem Tor für die Zonenausfahrt durchgeführt. Ein ähnliches Verhalten konnte schon während des Qualifikationslaufes B beobachtet werden. Um 09:54 wurde der Fahrentscheider letztmalig neu gestartet und versuchte, die Mission wieder aufzunehmen. Zwischenzeitlich war der Versuchsträger des Massachusetts Institute of Technology in die gleiche Freifahrtzone eingefahren. Im weiteren Verlauf näherten sich die autonomen Fahrzeuge einander, keines der Fahrzeuge setzte zu einem Ausweichmanöver an. Um 09:55 kam es zu einer Kollision, wodurch die Frontsensorik unseres Fahrzeugs dejustiert wurde. Wenige Sekunden später registrier-



(a) Wegstrecke bis zum Ausscheiden



(b) Kollision der Versuchsträger

te die Systemüberwachung einen Ausfall der Frontsensorik. Das Sensorsystem konnte zwar neu gestartet werden, doch durch die verbotene Sensorhalterung war die weitere Finalteilnahme unmöglich. Das Fahrzeug wurde aus dem Rennen genommen.

8.4 Fazit

Der Ausgang des Urban Challenge Wettbewerbes konnte die prinzipielle Machbarkeit einer autonomen Navigation im unstrukturierten und dynamischen urbanen Umfeld unter Beweis stellen. Der Einsatz autonomer mobiler Plattformen in dieser Umgebung ist ein Novum und wäre noch vor wenigen Jahren undenkbar gewesen. Es ist deshalb um so bemerkenswerter, dass bereits 11 Teams in einem vergleichsweise kurzen Entwicklungszeitraum von 2 Jahren eine erfolgreiche Finalteilnahme und immerhin 6 Teams die vollständige Bewältigung aller Missionen erreichen konnten. Es zeigt sich hierdurch eindrucksvoll der rasante Fortschritt der letzten Jahre in den Bereichen Robotik, maschinelle Umfeldwahrnehmung und künstliche Intelligenz.

Dennoch kann die Problemstellung der fahrerlosen Fahrt nicht als umfassend gelöst betrachtet werden. Die Komplexität aller teilnehmenden Versuchsträger, der technische Aufwand sowie der fast unbegrenzte Einsatz von Sensorik und Rechnerhardware sind Zeugen des notwendigen Entwicklungsprozesses, bevor ein seriennaher Einsatz der entwickelten Technologien denkbar ist - rechtliche Bedenken seien an dieser Stelle bewusst ausgeklammert. Nicht zuletzt durch die Wettbewerbsvorgaben blieben des Weiteren einige wichtige Aspekte weitgehend unberücksichtigt.

- Die starke Abhängigkeit vom gegebenen Kartenmaterial (Wegpunktlisten) und somit von der Satellitenortung und hochgenauen Navigationssystemen lässt sich nicht ohne

weiteres auf den Alltag übertragen. Für die Zukunft gilt es, alternative Ortungsverfahren zu entwickeln. Dies gilt insbesondere für die Relativpositionierung im Nahfeld. Das hier entwickelte kartenbasierte Umfeldmodell zur Fahrbereichsanalyse kann hierbei einen sinnvollen Beitrag leisten.

- Hochdynamische Vorgänge im Fahrzeugumfeld spielten im Wettbewerb eine nur untergeordnete Rolle. Überholvorgänge mit Gegenverkehr, Spurwechsel in fließendem Verkehr oder Einparkvorgänge auf belebten Parkflächen seien hier exemplarisch hervor gehoben. Diese stellen in der Praxis interessante Herausforderungen für die Sensorik sowie die übergeordneten Wahrnehmungs- und Bahnplanungsmodule dar.
- Wenig untersucht wurde auch das Verhalten der Versuchsträger in Ausnahmesituationen. Die sichere Behandlung regelwidrigen Verhaltens anderer Verkehrsteilnehmer durch eine autonome Plattform stellt völlig neue Anforderungen an die Bahn- und Missionsplanung sowie die Situationsanalyse und zeigt noch einigen Entwicklungsbedarf auf.

Weitere einschränkende Punkte wie die Performance bei Nacht oder schlechten Wetterbedingungen seien hier der Vollständigkeit halber erwähnt. Für das im Rahmen dieser Arbeit behandelte Fahrzeug ergeben sich somit einige wichtige Schlussfolgerungen:

- Die Fähigkeit zur Wahrnehmung und Interpretation unstrukturierter Umfeldbestandteile ist eine Schlüsselqualifikation für die autonome Navigation durch das urbane Umfeld. Die Kombination von objekt- und kartenbasierten Methoden in einem hybriden Umfeldmodell hat sich hierbei deutlich leistungsfähiger gezeigt als klassisch-objektbasierte Ansätze.
- Die Wahrnehmung unstrukturierter Umfeldbestandteile kann durch die Erhöhung der vertikalen Auflösungsfähigkeit der umfelderfassenden Sensorsysteme deutlich erleichtert werden. Dies zeigt sich eindrucksvoll in der Dominanz des Velodyne-LIDAR-Systems unter den 11 Finalisten, von denen lediglich drei Teams mit herkömmlicher Sensorik antraten.
- Die Kombination einer verhaltensbasierten Bahnplanung mit der deterministischen Arbeitsweise der zur Erweiterung herangezogenen Zustandsmaschinen ist extrem leistungsfähig und für die Weiterentwicklung gut geeignet. Die Flexibilität und Kreativität der Methodik erwiesen sich in vielen Situationen als Vorteil für unser Fahrzeug, allerdings auch in einigen Situationen als Nachteil. Auf mögliche und notwendige Weiterentwicklungen wird im nächsten Kapitel eingegangen.

9 Zusammenfassung und Ausblick

Im praktischen Verlauf dieser Arbeit wurde ein System zur automatischen Fahrzeugführung im urbanen Umfeld konzipiert und implementiert. Hierbei wurde für die maschinelle Wahrnehmung der Umgebung eine Kombination objekt- und kartenbasierter Umfeldmodelle in einem hybriden Gesamtsystem vorgenommen.

Die vorgestellte Fahrzeugarchitektur teilt sich in vier Schichten auf und umfasst eine Wahrnehmungs-, eine Interpretations-, eine Aktions- und eine Ausführungsebene.

Die Wahrnehmungsebene entkoppelt im Rahmen einer Akquisitionsschicht die Sensorikkomponenten von der Funktion und stellt ein zentrales Umfeldmodell zur Verfügung. Hierbei werden die Messdaten objekt- und nichtobjektgebender Sensoren auf Basis der LIDAR-, Radar- und Kameratechnologie miteinander fusioniert. Das Umfeldmodell ist als hybrides System ausgelegt und setzt sich zusammen aus einem objektbasierten Zweig zur Erfassung und Beschreibung von Hindernissen in der Umgebung des Versuchsträgers sowie einer kartenbasierten Modellierung des Fahrbereiches, welcher den Verlauf der Fahrbahnoberfläche wiedergibt.

Für die objektbasierte Hindernisdarstellung wird das Prinzip der Zustandsschätzung auf Basis eines erweiterten Kalmanfilters umgesetzt. Um die Beschreibung unstrukturierter Hindernisse zu ermöglichen, wird das Objektmodell durch das Prinzip lokaler Karten um eine Freiformdarstellung erweitert. Diese approximiert die Form beliebiger Objekte durch eine Reihe von Stützstellen auf der Objektkontur. Die mittlere Bewegung der Stützstellen während der Beobachtungszeit wird zur Schätzung der Objektdynamik verwendet. Die für die Zustandsschätzung notwendige Datenassoziation wird um die Berücksichtigung der Objektkonturen erweitert und ist als zweistufiger Prozess ausgelegt. Um eine Plausibilisierung der Messdaten im Rahmen der Zielinitialisierung zu ermöglichen, wird ein zusätzlicher Pretracking-Kreislauf eingeführt. Dieser berücksichtigt die Redundanz der Sensorsysteme in verschiedenen Abschnitten des Beobachtungsbereiches. Weiterhin erfolgt eine Kopplung mit dem kartenbasierten Modell zur Fahrbereichsanalyse, um den Einfluss störender Bodenreflexionen der LIDAR-Sensorik zu minimieren.

Die kartenbasierte Fahrbereichsanalyse erzeugt ein probabilistisches Abbild der Befahrbar-

keit auf Basis der Dempster-Shafer Methodik und dem Prinzip der Belegungskarten. Die Messdaten zweier auf die Fahrbahnoberfläche gerichteter LIDAR-Systeme werden genutzt, um eine Höhenkarte der Fahrzeugumgebung aufzubauen. Die Höhenkarte wird in eine korrespondierende Gradientendarstellung überführt, um die lokalen Unebenheiten des Umfelds zu quantifizieren. Der Gradient wird in eine probabilistische Dempster-Shafer-Beschreibung überführt. Die Höhe des Gradienten wird als Maß für die Unbefahrbarkeit der Umgebung herangezogen. Auf diese Weise lässt sich der glatte Straßenverlauf von vertikalen Kanten im Fahrbahn-Randbereich abheben.

Die gradientenbasierte Fahrbereichsanalyse wird erweitert um eine farbbasierte Klassifikation des Untergrundes. Hierbei wird das charakteristische Farbprofil der Fahrbahnoberfläche direkt vor dem Fahrzeug genutzt, um eine Segmentierung des durch ein Kamerasystem erhaltenen Abbilds der Umgebung durchzuführen. Die Segmentierung weist den Bildelementen ein Maß für deren Zugehörigkeit zur Fahrbahnoberfläche zu. Das auf diese Weise segmentierte Bild wird unter Ausnutzung der zuvor erhaltenen Höheninformation in die Umfeldkarte projiziert und in eine Dempster-Shafer-Beschreibung der Befahrbarkeit gewandelt. Die Dempster-Shafer Abschätzungen der Befahrbarkeit aus Gradienten- und Farbinformation werden nach dem Prinzip der Belegungskarten integriert und anschließend fusioniert.

Die Ausgangsdaten der objekt- sowie der kartenbasierten Umfeldmodellierung werden den Modulen zur Situationsinterpretation und Bahnplanung in der Interpretations- und Aktionsebene zur Verfügung gestellt. Diese bestehen aus einer Kombination verhaltens- und zustandsgesteuerter Algorithmen zur automatisierten Planung der Fahrentscheidungen. Als Planungsgrundlage wird auf eine Bahnplanung gemäß der Potentialfeldmethode zurückgegriffen. Eine Reihe möglicher Folgetrajektorien wird von jedem Punkt der Bahnplanung aus unter Berücksichtigung der Umfeld- und Missionsinformationen gewichtet und somit eine optimale Gesamtrajektorie bestimmt. Die für die Erweiterung herangezogenen Zustandsautomaten werden situationsabhängig aktiviert und sorgen für eine deterministische Behandlung von Spezialsituationen, wie z.B. dem Durchfahren einer Kreuzung bei gleichzeitiger Beachtung der Vorfahrtsregelungen.

Die erzeugten Solltrajektorien werden in der Aktionsebene einer dynamischen Bahnoptimierung unterzogen, um einen krümmungsoptimalen Sollverlauf für die unterlagerte Fahrzeugregelung in der Ausführungsebene zu erhalten. Diese bestimmt auf Basis der Sollbahn sowie der durch ein hochgenaues Ortungssystem verfügbaren Fahrzeugeigenposition die Stellgrößen für die Aktorik des Versuchsträgers. Zum Einsatz kommen klassische Reglerkomponenten sowie eine Vorsteuerung auf Basis der inversen Systemmodellierung.

Alle Komponenten des Fahrzeugsystems werden zyklisch durch eine zentrale Überwachungsebene kontrolliert. Diese ermöglicht im Fehlerfall das Anfahren eines sicheren Betriebszustandes sowie eine automatisierte Wiederherstellung der vollen Fahrzeugfunktionalität. Der

zeitweise Ausfall einer oder mehrerer Fahrzeugkomponenten führt auf diese Weise nicht zum Ausfall des Gesamtsystems.

Das Versuchsfahrzeug wurde im Rahmen des Projektes umfangreichen Erprobungen im Rahmen von Fahrversuchen unterzogen. Hierbei konnte iterativ das korrekte Verhalten für die Teilnahme am Urban Challenge Wettbewerb im November 2007 entwickelt werden. Im Rahmen des Wettbewerbes konnte die Finalteilnahme unter den besten 11 Teams des ursprünglich über 100 Fahrzeuge umfassenden Feldes erreicht werden. Auch wenn der Gesamtsieg nicht erstritten wurde, so ließ sich im erfolgreichen Halbfinale sowie in insgesamt 16 Kilometern Fahrtstrecke und zweistündiger Gesamt-Einsatzdauer in komplexer urbaner Umgebung während des Finales die Leistungsfähigkeit der entwickelten Fahrzeugplattform eindrucksvoll unter Beweis stellen. Die Platzierung im Feld der besten elf Teilnehmer bestehend aus einer Reihe internationaler Spitzenuniversitäten zeigte, dass auch bei begrenzten finanziellen und zeitlichen Ressourcen ein wettbewerbsfähiges Gesamtsystem entwickelt wurde.

Dennoch kann nicht gesagt werden, dass die Aufgabenstellung der fahrerlosen Fahrt im allgemeinen Straßenverkehr vollständig gelöst ist. Aufgrund des Projektumfangs, des engen zeitlichen Rahmens und nicht zuletzt der notwendigen Zielorientierung für eine Teilnahme am Urban Challenge Wettbewerb konnten manche interessante Fragestellungen nur gestreift werden und bieten Potential für zukünftige Forschungsarbeiten:

- Für die Umfeldwahrnehmung in komplexer Umgebung gilt es, eine noch engere Koppelung der karten- und objektbasierten Umfeldmodelle herbeizuführen. Der Projektverlauf hat gezeigt, dass die Fähigkeit zur Darstellung unstrukturierter Umfeldmerkmale eine Kernanforderung für die Fahrt in urbaner Umgebung ist. Aufgrund der Leistungsfähigkeit des entwickelten hybriden Umfeldmodells liegt es nahe, in Zukunft statische Karten der Fahrzeugumgebung unter Berücksichtigung der Randobjekte in Verbindung mit Objektlisten für dynamische Elemente der Fahrzeugumgebung zu betreiben. Eine Erweiterung der Umfeldkarte um weitere Abstraktionsebenen, der Austausch von Informationen über verschiedene Ebenen hinweg und somit die Schaffung einer Multi-Level-Datenfusion bieten hierbei interessante Perspektiven.

Für die Objektverfolgung ist es wünschenswert, aktuellste Ansätze zur Zielverfolgung unter Bestimmung der Existenzwahrscheinlichkeiten [84] auf das Prinzip der Freiform-Konturverfolgung zu übertragen. Bei weiter steigender Rechenleistung im Fahrzeug ist ferner die Bestimmung vollständiger lokaler Objektkarten (vgl. Abschnitt 6.1) anstelle der genäherten Polygondarstellung aussichtsreich. Zusätzlich sollte eine Klassifikation der Objektdaten auf Basis ihrer Form sowie durch Auswertung zusätzlicher, bildverarbeitender Systeme erfolgen.

- Für die Sensorik gilt es, den verfügbaren vertikalen Öffnungswinkel deutlich zu steigern. Einebenen- oder auch die hier verwendeten Vierebenen-Laserscanner lassen nur eingeschränkt eine Plausibilisierung des Umfeldes über dessen vertikale Struktur zu. Neben der aufwendigen LIDAR-Sensorik ist hier eine Kopplung des hybriden Umfeldmodells mit Methoden der Stereobildverarbeitung besonders vielversprechend.
- Bei der Bahnplanung und Situationsinterpretation sollte die Kombination verhaltens- und zustandsgesteuerter Algorithmen weiter verfeinert werden. Es gilt, die Kreativität der verhaltensbasierten Methoden zu erhalten und gleichzeitig mehr Determinismus für die Fahrentscheidungsfindung zu erzeugen. Die Einführung zusätzlicher Planungsebenen (z.B. auf Manöverebene) ist hier aussichtsreich.
Im Rahmen der hier vorgestellten Module sollte als erster Schritt die Potentialfeldmethode zur Bahnplanung durch Anwendung der in Kapitel 3.2 skizzierten vollständigen Suchverfahren erweitert werden. Auf diese Weise wird das Erreichen des Zielpunkts sichergestellt und es werden Planungsfehler durch lokale Minima des Potentialfeldes vermieden. Des Weiteren sollte bereits bei der Sollbahngenerierung die Berücksichtigung der Fahrzeugdynamik erfolgen, um die bislang notwendige, nachträgliche dynamische Bahnoptimierung zu vermeiden.
- Für die Ortung gilt es, eine Alternative zur hochgenauen Satellitenpositionierung zu entwickeln. Der Einsatz von low-cost Trägheitsplattformen und deren Kombination mit der kartenbasierten Umfeldwahrnehmung durch Anwendung bekannter Map-Matching-Verfahren [120] ist hier zielführend.

Die skizzierten Erweiterungen kombinieren klassische Technologien aus der Automobiltechnik bzw. Fahrerassistenz mit Ansätzen der mobilen Robotik. Die weitere Entwicklung auf diesem Feld kann mit Spannung verfolgt werden. Durch die vorliegende Arbeit wurden hoffentlich wichtige Grundsteine gelegt sowie Anregungen gegeben, die in zukünftigen Projekten verfolgt werden können und somit die Vision der fahrerlosen Fahrt ein weiteres Stück der Realität annähern.

A Koordinatensysteme und Transformationen

Für die im Rahmen dieser Arbeit zum Einsatz gebrachten Koordinatendarstellungen wird die Konvention der Luftfahrtnorm LN9300 [80] verwendet. Es wird unterschieden zwischen drei primären Koordinatendarstellungen:

- Das Sensorkoordinatensystem ist definiert durch den Anbauort sowie die Orientierung eines spezifischen Sensors am Fahrzeugträger. Jeder Sensor ermittelt Messdaten bezüglich seines lokalen Koordinatensystems.
- Unter dem Fahrzeugkoordinatensystem wird ein einheitliches, fahrzeugfestes Bezugssystem verstanden, das bezüglich eines beliebigen Referenzpunktes am Fahrzeugträger definiert ist.
- Das Weltkoordinatensystem ist ein inertiales (also erdfestes) Bezugskoordinatensystem, das bezüglich eines festen Referenzpunktes auf der Erdoberfläche definiert ist.

In der weiteren Notation sei die jeweils gültige Koordinatendarstellung als Subindex an den jeweiligen Orts- oder Richtungsvektor angefügt. So ist

$$\mathbf{p}_S = \begin{bmatrix} x_S & y_S & z_S \end{bmatrix}^T$$

die Darstellung eines Punktes in Sensorkoordinaten, \mathbf{p}_F die Darstellung in Fahrzeugkoordinaten und \mathbf{p}_W die Darstellung eines Punktes in Weltkoordinaten.

A.1 Allgemeine Koordinatentransformation

Unter dem Begriff Koordinatentransformation versteht man eine Abbildungsvorschrift, die zur Überführung eines Punktes zwischen zwei verschiedenen Koordinatendarstellungen benutzt wird. Die Koordinatentransformation setzt sich hierbei aus der Rotationsmatrix \mathbf{T}

und dem Translationsvektor \mathbf{t} zusammen. Im Rahmen dieser Arbeit wird für die Koordinatentransformation eine Definition mit Eulerwinkeln [20] genutzt. Die Rotationsmatrix \mathbf{T} ist gegeben durch:

$$\mathbf{T}(\Phi, \Theta, \Psi) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \Phi & \sin \Phi \\ 0 & -\sin \Phi & \cos \Phi \end{bmatrix} \cdot \begin{bmatrix} \cos \Theta & 0 & -\sin \Theta \\ 0 & 1 & 0 \\ \sin \Theta & 0 & \cos \Theta \end{bmatrix} \cdot \begin{bmatrix} \cos \Psi & \sin \Psi & 0 \\ -\sin \Psi & \cos \Psi & 0 \\ 0 & 0 & 1 \end{bmatrix}. \quad (\text{A.1})$$

Durch die Reihenfolge der Multiplikationen in Gleichung (A.1) ergibt sich folgender Ablauf:

- zunächst erfolgt eine mathematisch positive (Rechts-)Drehung um die Z-Achse des Koordinatensystems mit dem Gierwinkel Ψ ,
- anschließend eine mathematisch positive (Rechts-)Drehung um die Y-Achse des resultierenden Koordinatensystems mit dem Nickwinkel Θ und schließlich
- eine mathematisch positive (Rechts-)Drehung um die X-Achse des resultierenden Koordinatensystems mit dem Rollwinkel Φ .

Die Translation wird im Anschluss an die Rotation ausgeführt. Für die Überführung eines beliebigen Punktes von der Koordinatendarstellung 1 in die Koordinatendarstellung 2 ergibt sich

$$\mathbf{p}_2 = \mathbf{T}_{21} \cdot \mathbf{p}_1 + \mathbf{t}_{21}. \quad (\text{A.2})$$

Die inverse Rotationsmatrix einer Koordinatentransformation ist deren Transponierte. Es gilt

$$\mathbf{T}_{12} = \mathbf{T}_{21}^{-1} = \mathbf{T}_{21}^T. \quad (\text{A.3})$$

Für die Rücktransformation eines Punktes von der Darstellung 2 in die Darstellung 1 gilt daher folgender Zusammenhang:

$$\mathbf{p}_1 = \mathbf{T}_{12} \cdot \mathbf{p}_2 - \underbrace{\mathbf{T}_{12} \cdot \mathbf{t}_{21}}_{\mathbf{t}_{12}}. \quad (\text{A.4})$$

A.2 Festlegung der Koordinatendarstellungen

Im Folgenden gelte für die Koordinatensysteme des Versuchsträgers folgende Konvention:

- Der Ursprung des Fahrzeugkoordinatensystems liegt in der Mitte der Vorderachse. Die X-Achse zeigt in Richtung der Fahrzeug-Längsachse, die Y-Achse in Richtung der Fahrzeug-Querachse und die Z-Achse in Richtung der Fahrzeug-Hochachse.
- Der Ursprung des Weltkoordinatensystems liegt in einem fest definierten Referenzpunkt auf der Erdoberfläche. Die X-Achse zeigt in Richtung Osten, die Y-Achse in Richtung Norden, die Z-Achse zeigt senkrecht zur Erdoberfläche in den Himmel. Die Koordinaten des Referenzpunktes sind in der geodätischen Koordinatendarstellung (Längen- und Breitengrade) gegeben. Der Referenzpunkt liegt auf der Bezugshöhe Null Meter über dem Meeresspiegel.

Der Zusammenhang der Koordinatensysteme ist in Abb. A.1 dargestellt.




Abb. A.1: Koordinatensysteme für Umfelderfassung

A.2.1 Kalibrierparameter der Sensorik

Die Lage und Orientierung jedes Sensors in Bezug auf das Fahrzeug-Koordinatensystem ist durch Vermessung exakt bekannt. Der Zusammenhang beider Koordinatensysteme wird durch die Kalibrierparameter beschrieben. Diese sind im Detail:

- die Translation d_x des Sensors in X-Richtung des Fahrzeugkoordinatensystems,
- die Translation d_y des Sensors in Y-Richtung des Fahrzeugkoordinatensystems ,
- die Translation d_z des Sensors in Z-Richtung des Fahrzeugkoordinatensystems ,
- die Rotation γ des Sensors um die Z-Achse des Fahrzeugkoordinatensystems ,
- die Rotation β des Sensors um die Y-Achse und

- die Rotation α des Sensors um die X-Achse.

Hierbei ist die Reihenfolge der Rotationen gemäß Gleichung (A.1) einzuhalten. Die Transformationsparameter für eine Überführung vom Sensor- (S) ins Fahrzeugkoordinatensystem (F) errechnen sich zu

$$\begin{aligned} \mathbf{T}_{FS} &= \mathbf{T}(\alpha, \beta, \gamma) \quad \text{und} \\ \mathbf{t}_{FS} &= \begin{bmatrix} d_x & d_y & d_z \end{bmatrix}^T. \end{aligned} \quad (\text{A.5})$$

A.2.2 Umrechnung von geodätischen Koordinaten in Weltkoordinaten


Für eine Umrechnung von geodätischen Koordinaten in das kartesische Weltkoordinatensystem stehen verschiedene Kartenprojektionsverfahren zur Verfügung [42, 112]. Im Folgenden soll die polykonische Kartenprojektion unter der Annahme einer sphärischen Form des Erdballs mit Radius R angegeben werden. Der Ursprung des geodätischen Koordinatensystems liegt im Erdmittelpunkt. Für die kartesische Darstellung eines beliebigen Punktes auf der Erdoberfläche gilt

$$\begin{aligned} x_W &= \begin{cases} R \cdot \frac{\cos \phi}{\sin \phi} \cdot \sin E & , \phi \neq 0 \\ R \cdot (\lambda - \lambda_0) & , \phi = 0 \end{cases} \\ y_W &= \begin{cases} R \cdot \left[\phi - \phi_0 + \frac{\cos \phi}{\sin \phi} (1 - \cos E) \right] & , \phi \neq 0 \\ -R\phi_0 & , \phi = 0 \end{cases} \\ E &= (\lambda - \lambda_0) \cdot \sin \phi. \end{aligned} \quad (\text{A.6})$$


Der Ursprung des Weltkoordinatensystems wird durch den Bezugs-Längengrad λ_0 sowie den Bezugs-Breitengrad ϕ_0 festgelegt. Das polykonische Projektionsverfahren sorgt für eine Reihe von Verzerrungen, die mit dem Abstand zum Bezugspunkt zunehmen (Abb.A.2a und A.2b). Da der Einsatz des Systems in einem lokal begrenzten Gebiet um den Bezugspunkt herum erfolgt und weiterhin ausreichender Abstand von den Erdpolen sichergestellt ist, ergeben sich durch die Verzerrungen für die Praxis keine Einschränkungen.

A.2.3 Umrechnung von Fahrzeug- in Weltkoordinaten

Mit Hilfe des über die Ortungsplattform bereitgestellten Fahrzeugzustandsvektors ist eine Umrechnung von Fahrzeug- in Weltkoordinaten möglich. Es sei hierbei



(a) Erdoberfläche, 20°W-20°O, 0-50°N



(b) Polykonische Karte, 20°W-20°O, 0-50°N

Abb. A.2: Verzerrungen der polykonischen Kartenprojektion

- p_x die Position des Fahrzeugs in X-Richtung des Weltkoordinatensystems,
- p_y die Position des Fahrzeugs in Y-Richtung des Weltkoordinatensystems,
- p_z die Höhe des Fahrzeugs über dem Meeresspiegel,
- Ψ der Gierwinkel,
- Θ der Nickwinkel und
- Φ der Rollwinkel des Fahrzeugaufbaus.

Die Transformationsparameter errechnen sich gemäß Gleichung (A.1) zu:

$$\mathbf{T}_{WF} = \mathbf{T}(\Phi, \Theta, \Psi) \quad \text{und} \quad \mathbf{t}_{WF} = \begin{bmatrix} p_x & p_y & p_z \end{bmatrix}^T. \quad (\text{A.7})$$

A.2.4 Transformation von Geschwindigkeiten

Sind zwei Koordinatensysteme gegeneinander bewegt, so muss dies bei der Transformation von Geschwindigkeitsvektoren berücksichtigt werden. Dies trifft für die Transformation vom mitbewegten Fahrzeugkoordinatensystem in das inertielle Weltkoordinatensystem zu. Aus Gründen der Übersicht wird lediglich der ebene Fall ($z = 0$, keine Nick- oder Wankwinkel) betrachtet. Für die Transformation eines Ortsvektors erhält man gemäß Gleichung (A.7) und (A.1)

$$\begin{pmatrix} x_W \\ y_W \end{pmatrix} = \begin{pmatrix} x_F \cdot \cos \Psi - y_F \cdot \sin \Psi + x_{ego} \\ x_F \cdot \sin \Psi + y_F \cdot \cos \Psi + y_{ego} \end{pmatrix}. \quad (\text{A.8})$$

Die zeitliche Ableitung ergibt:

$$\begin{aligned} \begin{pmatrix} \dot{x}_W \\ \dot{y}_W \end{pmatrix} &= \begin{pmatrix} \dot{x}_F \cdot \cos \Psi - \dot{y}_F \cdot \sin \Psi - x_F \cdot \sin \Psi \cdot \dot{\Psi} - y_F \cdot \cos \Psi \cdot \dot{\Psi} + \dot{x}_{ego} \\ \dot{x}_F \cdot \sin \Psi + \dot{y}_F \cdot \cos \Psi + x_F \cdot \cos \Psi \cdot \dot{\Psi} - y_F \cdot \sin \Psi \cdot \dot{\Psi} + \dot{y}_{ego} \end{pmatrix} \\ &= \underbrace{\begin{bmatrix} \cos \Psi & -\sin \Psi \\ \sin \Psi & \cos \Psi \end{bmatrix}}_{\mathbf{v}_1} \cdot \begin{pmatrix} \dot{x}_F \\ \dot{y}_F \end{pmatrix} \\ &\quad + \underbrace{\begin{bmatrix} -\dot{\Psi} \cdot \sin \Psi & -\dot{\Psi} \cdot \cos \Psi \\ \dot{\Psi} \cdot \cos \Psi & -\dot{\Psi} \cdot \sin \Psi \end{bmatrix}}_{\mathbf{v}_2} \cdot \begin{pmatrix} x_F \\ y_F \end{pmatrix} \\ &\quad + \underbrace{\begin{pmatrix} \dot{x}_{ego} \\ \dot{y}_{ego} \end{pmatrix}}_{\mathbf{v}_3}. \end{aligned} \quad (\text{A.9})$$

Der resultierende Geschwindigkeitsvektor in Weltkoordinaten setzt sich zusammen aus der Transformation des lokalen Geschwindigkeitsvektors \mathbf{v}_1 , der additiven Scheinkomponente \mathbf{v}_2 und der translatorischen Differenzbewegung der beiden Koordinatensysteme \mathbf{v}_3 . Die Scheinkomponente ist abhängig vom Abstand zwischen Fahrzeug-Ursprung und dem Ursprung des Geschwindigkeitsvektors sowie von der Gierrate $\dot{\Psi}$ des Fahrzeugs.

A.3 Besondere Koordinatensysteme

Über die primären Koordinatendarstellungen hinaus sind im Rahmen dieser Arbeit zwei spezielle Koordinatensysteme relevant.

A.3.1 Diskrete Weltkoordinaten

In der diskreten Darstellung des kartenbasierten Umfeldmodells treten anstelle kontinuierlicher x - und y -Positionen die Gitterkoordinaten der Karte. Ein Punkt im diskreten Koordinatensystem sei wie folgt definiert:

$$\mathbf{p}_D = \begin{bmatrix} i & j & h \end{bmatrix}^T. \quad (\text{A.10})$$

Hierbei ist h die (nicht-diskrete) Höhe über dem Meeresspiegel. Es gilt für eine beliebige Karte mit der Auflösung Δx bzw. Δy und dem Referenzpunkt \mathbf{p}_W^{ref} sowie dessen korrespondierenden Gitterkoordinaten (i^{ref}, j^{ref}) :

$$\mathbf{p}_D = \Xi(\mathbf{p}_W, \mathbf{p}_W^{ref}, i^{ref}, j^{ref}, \Delta x, \Delta y) = \begin{pmatrix} \text{round} \frac{x_W - x_W^{ref}}{\Delta x} \\ \text{round} \frac{y_W - y_W^{ref}}{\Delta y} \\ z_W \end{pmatrix}. \quad (\text{A.11})$$

Die Abbildung Ξ ist durch die Rundung in Gleichung A.11 surjektiv, aber nicht injektiv. Die exakte Positionsangabe geht durch die Diskretisierung verloren. Der Zusammenhang zwischen diskreten Koordinaten und kontinuierlichen Weltkoordinaten ist in Abb. A.3 dargestellt.




Abb. A.3: Diskretes Koordinatensystem der kartenbasierten Darstellung

A.3.2 Kamerakoordinaten

Bei der Arbeit mit bildgebenden Sensoren wird zwischen intrinsischen und extrinsischen Kalibrierparametern unterschieden. Während die intrinsischen Parameter die optischen Eigenschaften von Kamera und Objektiv beschreiben, legen die extrinsischen Parameter die

Lage und Orientierung der Kamera bezüglich eines beliebigen Referenzkoordinatensystems fest. Das Sensorkoordinatensystem einer Kamera sei hierbei wie folgt definiert: Der Ursprung liegt im optischen Zentrum (Brennpunkt) des Objektivs, die X-Achse zeigt in der Bildebene nach rechts entlang der Bildspalten, die Y-Achse nach oben entgegen der Bildzeilen (vgl. Abb. A.4). Um den optischen Pfad jedes einzelnen Bildpunkts zu beschreiben, ist die Ver-




Abb. A.4: Kamerakoordinatensystem

wendung eines Kameramodells notwendig, das die Eigenschaften des verwendeten Objektivs mit einbezieht. Im Rahmen dieser Arbeit wird hierzu das in [59] vorgestellte Modell benutzt. Zunächst bildet man einen beliebigen Punkt \mathbf{p}_S im Sensorkoordinatensystem linear durch den Brennpunkt auf die Bildebene ab. Es ergibt sich für die Projektion

$$\mathbf{p}_B = \begin{pmatrix} x_B \\ y_B \\ z_B \end{pmatrix} = f \cdot \begin{pmatrix} x_S/z_S \\ y_S/z_S \\ 1 \end{pmatrix}. \quad (\text{A.12})$$

Der Term wird mit der Brennweite f normiert zu $\mathbf{p}'_B = \frac{1}{f}\mathbf{p}_B$. Um die Verzerrungen des Objektivs zu berücksichtigen, setzt man folgenden nichtlinearen Zusammenhang an:

$$\begin{aligned} \mathbf{p}''_B &= (1 + k_1 \cdot r^2 + k_2 \cdot r^4 + k_5 \cdot r^6) \cdot \mathbf{p}'_B + \mathbf{t}, \quad \text{mit} \\ r^2 &= x_B'^2 + y_B'^2 \quad \text{und} \\ \mathbf{t} &= \begin{pmatrix} 2 \cdot k_3 x'_B y'_B + k_4 \cdot (r^2 + 2x_B'^2) \\ k_3 \cdot (r^2 + 2y_B'^2) + 2k_4 \cdot x'_B y'_B \end{pmatrix}. \end{aligned} \quad (\text{A.13})$$

Im letzten Schritt wird von der normierten und verzerrten Position in der Bildebene auf die tatsächliche Pixelebene der Kamera umgerechnet. Hierbei fließen die tatsächliche Brennweite der Kamera, die Dimensionen der Pixel sowie das Seitenverhältnis und das optische Zentrum

der Kamera mit ein. Die Darstellung des Punktes in Pixelkoordinaten \mathbf{p}_P ergibt sich zu

$$\mathbf{p}_P = \begin{pmatrix} x_P \\ y_P \\ 1 \end{pmatrix} = \begin{bmatrix} f_1 & \alpha_c \cdot f_1 & cc_1 \\ 0 & f_2 & cc_2 \\ 0 & 0 & 1 \end{bmatrix} \cdot \mathbf{p}'_B. \quad (\text{A.14})$$

Die intrinsischen Kalibrierparameter f_1 , f_2 , α_c , cc_1 und cc_2 sowie k_1 bis k_5 lassen sich durch den Einsatz gängiger Kalibrierrouninen [18] aus definierten Testbildern erzeugen. Bei bekannter Ausrichtung des Fahrzeugs in Bezug auf ein definiertes Testmuster lässt sich damit auch die extrinsische Kalibrierung der Kamera durchführen.


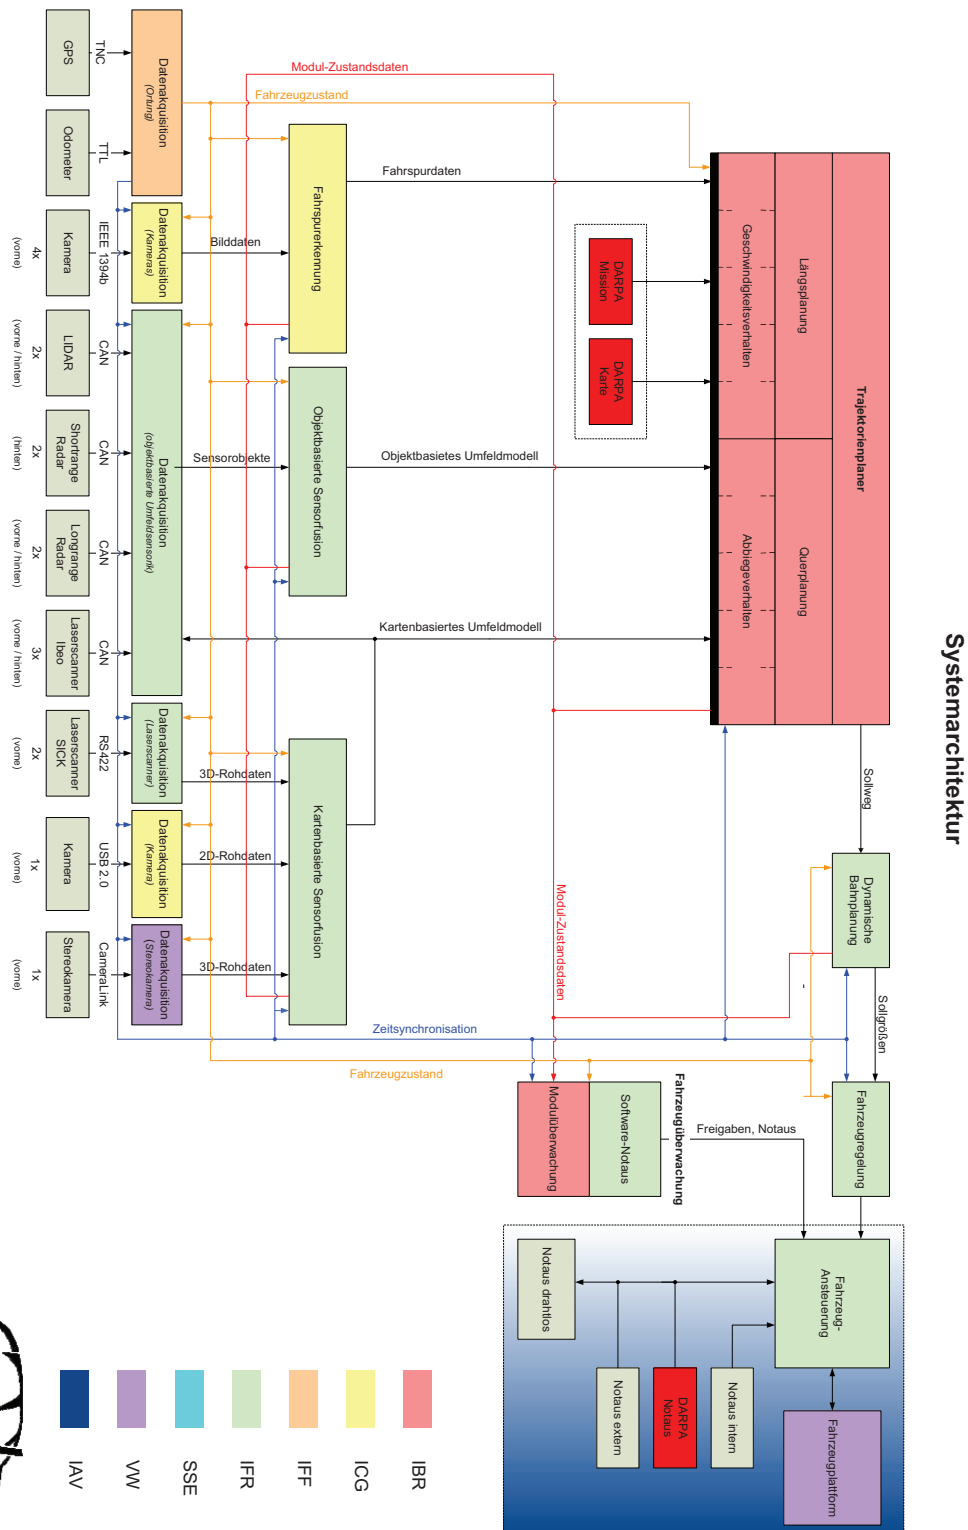


Abb. A.5: Extrinsische Kamerakalibrierung

B Fahrzeugarchitektur



Literatur

- [1] ABRAHAM, C. ; GURTOVOY, A.: *C++ Template Metaprogramming: Concepts, Tools, and Techniques from Boost and Beyond*. Addison-Wesley, 2004
- [2] Bundesministerium für Wirtschaft und Technologie: *AKTIV: Adaptive und kooperative Technologien für den intelligenten Verkehr*. <http://www.aktiv-online.org>
- [3] BAR-SHALOM, Y.: On the Track-to-Track Correlation Problem. In: *IEEE Transactions on Automatic Control* 26(2) (1981), S. 571 – 572
- [4] BAR-SHALOM, Y.: *Multitarget-Multisensor Tracking: Advanced Applications*. Artech House, 1990
- [5] BAR-SHALOM, Y.: Update with Outof-Sequence Measurements in Tracking: Exact Solution. In: *IEEE Transactions on Aerospace and Electronic Systems* 38 (2002), Nr. 3, S. 769 – 778
- [6] BAR-SHALOM, Y. ; FORTMANN, T. E.: *Tracking and Data Association*. Academic Press Inc, 1988
- [7] BAR-SHALOM, Y. ; FORTMANN, T.E.: *Estimation and Tracking - Principles, Techniques and Software*. Artech House, 1993
- [8] BAR-SHALOM, Y. ; MALLICK, M. ; CHEN, H. ; WASHBURN, R.: Onestep solution for the general out-of-sequence measurement problem in tracking. In: *In Proceedings of the 2002 IEEE Aerospace Conference*, 2002
- [9] BASARKE, C. ; BERGER, C. ; RUMPE, B.: Software and Systems Engineering Process and Tools for the Development of Autonomous Driving Intelligence. In: *Journal of Aerospace Computing, Information, and Communication (JACIC)* 4 (2007), Nr. 12, S. 1158–1174
- [10] BAUER, M.: *Ein evidenztheoretischer Ansatz zur Planerkennung*, Universität Saarland, Diss., 1996
- [11] BECK, S.: *Ein Konzept zur automatischen Lösung von Entscheidungsproblemen bei Unsicherheit mittels der Theorie der unscharfen Mengen und der Evidenztheorie*, Institut für angewandte Informatik, Universität Karlsruhe, Diss., 2004
- [12] BECKER, J.-C.: *Fusion der Daten der objekterkennenden Sensoren eines autonomen Straßenfahrzeugs*, Institut für Regelungstechnik, TU Braunschweig, Diss., 2002
- [13] BERGER, K.: *Recognizing driveable terrain - an analysis of clustering methods*, Institut für Computergrafik, TU Braunschweig, Studienarbeit, 2002

- [14] BERLER, A. ; SHIMONY, S.E.: Bayes Networks for Sensor Fusion in Occupancy Grids / Dept. of Math. and Computer Science, Ben Gurion University of the Negev. Version: 1996. <http://www.cs.bgu.ac.il/ami/publications/techreport.ps>. Beer-Sheva, Israel, 1996. – Forschungsbericht
- [15] BILMES, J. A.: A gentle tutorial on the EM algorithm and its application to parameter estimation for gaussian mixture and hidden markov models. 1997. – Forschungsbericht
- [16] BLACKMAN, S.S.: *Multiple-Target Tracking with Radar Applications*. Artech House, 1986
- [17] BLACKMAN, S.S. ; POPOLI, R.: *Design and Analysis of Modern Tracking Systems*. Artech House, 1999
- [18] BOUGUET, J.-Y.: *Camera Calibration Toolbox for Matlab*. <http://vision.caltech.edu/bouguetj/calib/doc>
- [19] BRESENHAM, J.E.: Algorithm for computer control of a digital plotter. In: *ACM Seminal graphics: pioneering efforts that shaped the field* (1998), S. 1 – 6
- [20] BRONSTEIN, I.N. ; SEMENDJAJEW, K.A. ; MUSIOL, G. ; MÜHLIG, H.: *Taschenbuch der Mathematik*. Verlag Harry Deutsch, 1999
- [21] BRUCE, J. ; BALCH, T. ; VELOSO, M.: Fast and inexpensive color image segmentation for interactiverobots. In: *In Proceedings of IEEE International Conference on Intelligent Robots and Systems* Bd. 3, 2000, S. 2061 – 2066
- [22] CHEN, Q. ; ÖZGÜNER, Ü.: Intelligent Off-Road Navigation Algorithms and Strategies of Team Desert buckeyes in the DARPA Grand Challenge '05. In: *Springer tracts in advanced robotics - The 2005 DARAP Grand Challenge 36* (2007), S. 45 – 102
- [23] COMANICIU, D. ; MEER, P.: Robust analysis of feature spaces: color image segmentation. In: *In Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1997, S. 750 – 755
- [24] COUÉ, C. ; PRADALIER, C. ; LAUGIER, C.: Bayesian programming for multi-target tracking: an automotive application. In: *In Proceedings of the International Conference on Field and Service Robotics*, 2003
- [25] COUÉ, C. ; PRADALIER, C. ; LAUGIER, C. ; FRAICHARD, T. ; BESSIÈRE, Pierre: Bayesian Occupancy Filtering for Multi-Target Tracking. In: *International Journal of Robotic Research (IJRR)* 25 (2005), Nr. 1
- [26] CRASSIDIS, J.L.: Sigma-Point Kalman Filtering for Integrated GPS and Inertial Navigation. In: *In Proceedings of AIAA Guidance, Navigation, and Control Conference and Exhibit*. San Francisco, CA, USA, 2005
- [27] DARMS, M. ; WINTER, H.: Eine Systemarchitektur zur Fusion von Umfelddaten. In: *In Proceedings of VDI Tagung Aktive Sicherheit durch Fahrerassistenz*. München, 2004
- [28] DARPA: *Urban Challenge Technical Evaluation Criteria*. <http://www.darpa.mil/grandchallenge/docs>. Version: 2006

- [29] DARPA: *Urban Challenge Rules*. <http://www.darpa.mil/grandchallenge/docs>. Version: 2007
- [30] DECHTER, R. ; PEARL, J.: Generalized best-first search strategies and the optimality of A*. In: *Journal of the ACM* (1985), S. 505 – 536
- [31] DEMPSTER, A.P.: Upper and lower probabilities induced by multivalued mapping. In: *Annals of Mathematical Statistics* 38 (1967), S. 325 – 339
- [32] DEVENDRA, M.K. ; ZACHERY, G.R.: Multi-Sensor Fusion Strategy to Obtain 3-D Occupancy Profile. In: *In Proceedings of IEEE Industrial Electronics Society, IECON2005*, 2005, S. 6 – 12
- [33] DIARD, Julien ; BESSIÈRE, Pierre ; MAZER, Emmanuel: A survey of probabilistic models, using the bayesian programming methodology as a unifying framework. In: *In Proceedings of the 2nd. International Conference on Computational Intelligence, Robotics and Autonomous Systems (CIRAS 2003)*, 2003
- [34] DIETMAYER, K. ; SPARBERT, J. ; STRELLER, D.: Model based classification and object tracking in traffic scenes from range-images. In: *In Proceedings of the IEEE Intelligent Vehicles Symposium*. Tokio, Japan, 2001
- [35] EDELSBRUNNER, H. ; NIMISH, S.: Incremental Topological Flipping Works for Regular Triangulations. In: *Algorithmica* 14 (1996), Nr. 3, S. 223 – 241
- [36] EFFERTZ, J.: *Multi Sensor Joined Probabilistic Data Association zur Objekterkennung und Verfolgung in einem Multi-Sensor-Netzwerk*, Institut für Regelungstechnik, TU Braunschweig, Studienarbeit, 2002
- [37] EFFERTZ, J.: An Expandable Multi-Sensor Data-Fusion Concept for Autonomous Driving in Urban Environments. In: *Journal of Aerospace Computing, Information, and Communication* 4 (2007)
- [38] EFFERTZ, J.: Tracking und Datenfusion mit Multi-Modell-Filtern. In: *AAET 2007*, 2007
- [39] EFFERTZ, J.: Sensor Architecture and Data Fusion for Robotic Perception in Urban Environments at the 2007 DARPA Urban Challenge. In: *2nd Workshop Robot Vision*, 2008
- [40] EFFERTZ, J. ; FORM, T. ; WILLE, J.-M.: Urban Challenge 2007: Autonomes Fahren in dynamischen Umgebungen. In: *IQ-Journal VDI/VDE Bezirksvereine Braunschweig e. V.* (2007)
- [41] ELFES, A.: Occupancy grids: A stochastic spatial representation for active robot perception. In: *IEEE Computer Society Press, Autonomous Mobile Robots* (1991), S. 46 – 57
- [42] EVENDEN, G.I.: *Cartographic Projection Procedures for the UNIX Environment*. User's Manual, 1990

- [43] EWALD, A. ; WILLHOEFT, V.: Laser scanners for obstacle detection in automotive applications. In: *In Proceedings of IEEE Intelligent Vehicles Symposium 2000*, 2000, S. 682 – 687
- [44] FIORETTI, G.: A Mathematical Theory of Evidence for G.L.S. Shackle. Torino, Italia, 2001. – Forschungsbericht
- [45] FLOUDAS, N. ; TSOVAS, M. ; AMDITIS, A. ; POLYCHRONOPOULOS, A.: Track Level Fusion for Object Recognition in Road Environments. 2 (2008), S. 16 – 23
- [46] FORTYTH, D.A. ; PONCE, J.: *Computer Vision: A Modern Approach*. Prentice Hall, 2002
- [47] FRANKE, U. ; GEHRIG, S.K. ; BADINO, H. ; RABE, C.: Towards Optimal Stereo Analysis of Image Sequences. In: *In Proceedings of 2nd International Workshop on Robot Vision (RobVis08)*. Auckland, New Zealand, 2008, S. 43 – 58
- [48] FRANKE, Uwe ; RABE, Clemens ; BADINO, Hernán ; GEHRIG, Stefan: 6d-vision: Fusion of stereo and motion for robust environment perception. In: *In Proceedings of DAGM 05*, 2005
- [49] FRIEDBERG, S.H. ; SPENCE, A.J. Inseland L.: *Linear algebra*. Prentice Hall, 1989
- [50] FUERSTENBERG, Kay C. ; DIETMAYER, Klaus C. J. ; EISENLAUER, Stephan ; WILLHOEFT, Volker: Multilayer Laserscanner for robust Object Tracking and Classification in Urban Traffic Scenes. In: *Proceedings of ITS 2002, 9th World Congress on Intelligent Transport Systems*, 2002, S. 7 – 8
- [51] FULGENZI, C. ; SPALANZANI, A. ; LAUGIER, C.: Dynamic Obstacle Avoidance in uncertain environment combining PVOs and Occupancy Grid. In: *In Proceedings of IEEE International Conference on Robotics and Automation*, 2007, S. 1610 – 1616
- [52] FÄRBER, B.: (Un)sichtbare Beifahrer - was Autofahrer von Fahrerassistenzsystemen erwarten (können). In: *Fahrerassistenzsysteme: Innovationen im Dienste der Sicherheit, 12. DVR Forums Sicherheit und Mobilität*. München, Germany, 2006
- [53] FÖLSTER, F. ; RITTER, H. ; ROHLING, H.: Lateral Velocity Estimation for Automotive Radar Applications. In: *In Proceedings of the International Conference on Radar Systems*. Edinburgh, UK, 2007
- [54] FÖLSTER, F. ; SCHULZ, R. ; MÜLLER, S. ; ROHLING, H. ; GIEBEL, T.: Advanced Driver Assistance Systems based on Radar Sensors. In: *In Proceedings of 4th International Workshop on Intelligent Transportation (WIT)*. Hamburg, Germany, 2007
- [55] GAMMA, E. ; HELM, R. ; JOHNSON, R. ; VLISSIDES, J.: *Design Patterns: Elements of Reusable Object-Oriented Software*. Addison-Wesley Professional, 1995
- [56] GOLDBECK, J. ; HUERTGEN, B.: Lane detection and tracking by video sensors. In: *In Proceedings of IEEE Intelligent Transportation Systems*, 1999, S. 74 – 79
- [57] HARRIS, C.J. u. a.: Multi Sensor Data Fusion for Defence and Aerospace. In: *The Aeronautical Journal* 102 (1998), S. 229 – 244

- [58] HARTLEY, R. ; ZISSERMAN, A.: *Multiple View Geometry in Computer Vision*. Cambridge University Press, 2003
- [59] HEIKKILÄ, J. ; SILVÉN, O.: A Four-step Camera Calibration Procedure with Implicit Image Correction. In: *In Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. San Juan, Puerto Rico, 1997, S. 1106 – 1112
- [60] HENNESSY, J.L. ; PATTERSON, A.: *Computer Architecture - A Quantitative Approach*. San Fransisco, California : Morgan Kaufman Publishers, INC., 1996
- [61] HERMAN, S.M.: *A Particle Filtering Approach to Joint Passive Radar Tracking and Target Classification*, University of Illinois at Urbana-Champaign, Diss., 2002
- [62] HOSEINNEZHAD, R. ; MOSHIRI, B. ; ASHARIF, M.R.: Sensor fusion for ultrasonic and laser arrays in mobile robotics: a comparative study of fuzzy, Dempster and Bayesian approaches. In: *In Proceedings of the IEEE Sensors 2002* Bd. 2, 2002, S. 1682 – 1689
- [63] HÄNSLER, E.: *Statistische Signale*. Springer Verlag, 1996
- [64] Intel Cooperation: *Intel Pentium 4 Processor*. Datasheet. <http://www.intel.com>
- [65] Europäische Union: *INTERSAFE-2: Cooperative Intersection Safety*. <http://www.intersafe-2.eu>
- [66] KAEMPCHEN, N.: *Feature-Level Fusion of Laser Scanner and Video Data for Advanced Driver Assistance Systems*, Universität Ulm, Fakultät für Ingenieurwissenschaften und Informatik, Diss., 2007
- [67] KAEMPCHEN, N. ; DIETMAYER, K.: Fusion of laserscanner and video for advanced driver assistance systems. In: *In Proceedings of the 11th World Congress on Intelligent Transportation Systems*. Nagoya, Japan, 2004
- [68] KHAMMARI, A. ; NASHASHIBI, F. ; ABRAMSON, Y. ; LAURGEAU, C.: Vehicle detection combining gradient analysis and AdaBoost classification. In: *In Proceedings of IEEE Intelligent Transportation Systems*, 2005, S. 66 – 71
- [69] KIRCHNER, A. ; AMELING, C.: Integrated obstacle and road tracking using a laser scanner. In: *In Proceedings of Intelligent Vehicles Symposium*. Dearborn, MI, USA, 2000, S. 674 – 681
- [70] KIRCHNER, A. ; LAGES, U. ; TIMM, K.: Der Laserscanner als intelligenter Kfz-Sensor. In: *ATP - Automatisierungstechnische Praxis* 8 (1998), S. 26 – 34
- [71] KLOSE, F.: *Sensorfusion von flächigen Umfelddaten anhand von Belegungskarten*, Institut für Regelungstechnik, TU Braunschweig, Diplomarbeit, 2008
- [72] KLOTZ, M.: *An Automotive Short Range High Resolution Pulse Radar Network*, Technische Universität Hamburg-Harburg, Diss., 2002
- [73] KLUGE, K. ; LAKSHMANAN, S.: A deformable-template approach to lane detection. In: *In Proceedings of the Intelligent Vehicles Symposium*, 1995, S. 54 – 59

- [74] KOKS, D. ; CHALLA, S.: An introduction to Bayesian and Dempster-Shafer Data Fusion / Defence Science and Technology, Electronic Warfare and Radar Division. Edinburgh, Australia, 2003. – Forschungsbericht
- [75] LATOMBE, J.-C.: *Robot Motion Planning*. Kluwer Academic Publishers, 1991
- [76] LEFEBVRE, T. ; BRUYNINCKX, H. ; SCHUTTER, J. D.: Comment on A New Method for the Nonlinear Transformation of Means and Covariances in Filters and Estimators. In: *Correspondence to IEEE Transactions on Automatic Control* 45 (2000), Nr. 3, S. 477 – 482
- [77] LEFEBVRE, T. ; BRUYNINCKX, H. ; SCHUTTER, J. D.: Kalman filters for non-linear systems: a comparison of performance. In: *International Journal of Control* 7 (2004), S. 639 – 653
- [78] LEFEBVRE, T. ; BRUYNINCKX, Herman ; SCHUTTER, J. D.: Kalman Filters for non-linear systems: a comparison of performance. In: *International Journal of Control* 77 (2001), S. 639 – 653
- [79] LIPSKI, C. ; SCHOLZ, B. ; BERGER, K. ; LINZ, C. ; STICH, T. ; MAGNOR, M.: A Fast and Robust Approach to Lane Marking Detection and Lane Tracking. In: *In Proceedings of IEEE Southwest Symposium on Image Analysis and Interpretation (SSIAI-2008)*, 2008
- [80] DIN: *Deutsche Luftfahrtnorm LN 9300 - Bezeichnungen in der Flugmechanik*. 1970
- [81] LUNZE, J.: *Regelungstechnik 2: Mehrgrößensysteme, Digitale Regelung*. Springer Verlag, 2008
- [82] MACQUEEN, J.B.: Some Methods for classification and Analysis of Multivariate Observations. In: *In Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability*. Berkeley, University of California, 1967
- [83] MAEHLISCH, M. ; KAUDERER, T. ; RITTER, W. ; DIETMAYER, K.: Feature-Level Video and Multibeam Lidar Sensor Fusion for Full-Speed ACC State Estimation. Hamburg, Germany, 2007
- [84] MAEHLISCH, M. ; RITTER, W. ; DIETMAYER, K.: ACC Vehicle Tracking with Joint Multisensor Multitarget Filtering of State and Existence. In: *PreVENT Fusion Forum e-Journal* 1 (2006), S. 34 – 43
- [85] MAHLER, R.: Random sets: Unification and computation for information fusion. In: *In Proceedings of the International Conference on Information Fusion*, 2004, S. 1 – 20
- [86] MCCALL, J.C. ; TRIVEDI, M.M.: An integrated, robust approach to lane marking detection and lane tracking. In: *In Proceedings of the IEEE Intelligent Vehicles Symposium*, 2004, S. 533 – 537
- [87] MEINECKE, M.-M.: *Zum optimierten Sendesignalentswurf für Automobilradare*, Technische Universität Hamburg-Harburg, Diss., 2001

- [88] MEINECKE, M.-M. ; ROHLING, H.: Combination of LFM CW and FSK Modulation Principles. In: *In Proceedings of German Radar Symposium GRS2000*. Berlin, Germany, 2000
- [89] MERZIGER, G. ; WIRTH, T.: *Repetitorium der höheren Mathematik*. Hannover, Germany : Binomi-Verlag
- [90] MILLS, D.L.: Internet Time Synchronization: The Network Time Protocol. In: *IEEE Transactions on Communications* 39 (1991), Nr. 10
- [91] MITSCHKE, M. ; WALLENTOWITZ, H.: *Dynamik der Kraftfahrzeuge*. Springer Verlag, 2004
- [92] MOBUS, R. ; KOLBE, U.: Multi-target multi-object tracking, sensor fusion of radar and infrared. In: *In Proceedings of IEEE Intelligent Vehicles Symposium 2004*, 2004, S. 732 – 737
- [93] MORAVEC, H.P.: Sensor Fusion in Certainty Grids for Mobile Robots. In: *AI-Magazine* 9 (1988), S. 61 – 74
- [94] MULLANE, J. ; ADAMS, M.D. ; WIJESOMA, W.S.: Evidential versus Bayesian Estimation for Radar Map Building. In: *In Proceedings of the 9th International Conference on Control, Automation, Robotics and Vision ICARCV*, 2006, S. 1 – 8
- [95] MÖLLER, T. ; KRAFT, H. ; FREY, J. ; ALBRECHT, M. ; LANGE, R.: Robust 3D Measurement with PMD Sensors. In: *In Proceedings of Range Imaging Day 2005*. Zürich, Switzerland, 2005
- [96] MÜLLER, K.: *Entwurf robuster Regelungen*. Stuttgart, Germany : B.G. Teubner, 1996
- [97] NEUMAIER, S. ; FÄRBER, G.: Videobasierte Fahrspurerkennung zur Umfelderkennung bei Straßenfahrzeugen. In: *Informatik Aktuell - Autonome Mobile Systeme 2005* (2005), S. 173 – 178
- [98] OFFICE, Congressional B.: *The National Defense Authorization Act for Fiscal Year 2001*. <http://www.cbo.gov>. Version: 2001
- [99] OHL, S.: *Entwicklung einer Multi-Sensor-Datenfusion für ein autonomes Straßenfahrzeug*, Institut für Regelungstechnik, TU Braunschweig, Diplomarbeit, 2007
- [100] Omnistar USA Inc.: *Worldwide Differencial Global Positioning Servive*. <http://www.omnistar.com/about.html>
- [101] P. STEPAN, P. ; KULICH, M. ; PREUCIL, L.: Robust data fusion with occupancy grid. In: *IEEE Transactions on Systems, Man and Cybernetics* 35 (2005), Nr. 1, S. 106 – 115
- [102] PEGL, L.A. ; TILLER, W.: *The NURBS Book*. Springer Verlag, 1996
- [103] Europäische Union: *PREVENT: Preventive and Active Safety Applications*. <http://www.prevent-ip.org>

- [104] PUNSKA, O.: *Bayesian Approaches for Multi-Sensor Data Fusion*, University of Cambridge, Signal Processing and Communications Laboratory, Diss., 1999
- [105] RAUSKOLB, F.W. u. a.: Caroline: An Autonomously Driving Vehicle for Urban Environments. In: *Journal of Field Robotics* 25 (2008), S. 674 – 724
- [106] RHEINHOLTZ, C. u. a.: DARPA Urban Challenge Technical Paper. 2007. – Forschungsbericht
- [107] ROSENBLATT, J.: DAMN: A Distributed Architecture for Mobile Navigation / Robotics Institute, Carnegie Mellon University. 1997. – Forschungsbericht
- [108] SCHNEIDER, U.: *Sensordatenfusion und Fehlerkalibrierung von umfelder kennenden Sensoren eines Straßenfahrzeugs*, Institut für Regelungstechnik, TU Braunschweig, Diss., 2005
- [109] SCHWARTE, R.: New Powerful Sensory Tool in Automotive Safety Systems Based on PMD-Technology. In: *In Proceedings of AMAA - Advanced Microsystems for Automotive Applications 2000*. Berlin, Germany, 2000
- [110] SENTZ, K. ; FERSON, S.: Combination of evidence in Dempster-Shafer theory / Systems Science and Industrial Engineering Department, Binghamton University. 2002. – Forschungsbericht
- [111] SHAFER, G.: *A Mathematical Theory of Evidence*. Princeton University Press, 1976
- [112] SNYDER, J.P.: Map Projections - A Working Manual. 1987. – Forschungsbericht
- [113] ST.PIERRE, M. ; GINGRAS, D.: Comparison between the unscented Kalman filter and the extended Kalman filter for the position estimation module of an integrated navigation information system. In: *In Proceedings of the 2004 IEEE Intelligent Vehicles Symposium*, 2004, S. 831 – 835
- [114] STÜKER, D.: *Heterogene Sensordatenfusion zur robusten Objektverfolgung im automobilen Straßenverkehr*. Oldenburg, Germany, Carl von Ossietzky Universität, Diss., 2004
- [115] SÄRKKÄ, S. ; VEHTARI, A. ; LAMPINEN, J.: Rao-Blackwellized Monte Carlo data association for multiple target tracking. In: *In Proceedings of the Seventh International Conference on Information Fusion*, 2004, S. 583 – 590
- [116] TALOS: Technical Report - DARPA Urban Challenge / Massachusetts Institute of Technology. 2007. – Forschungsbericht
- [117] THRUN, S. u. a.: Autonomous Exploration and Mapping of Abandoned Mines. In: *IEEE Robotics and Automation Magazine* 11 (2004), Nr. 4, S. 79 – 91
- [118] THRUN, S. u. a.: Stanley: The Robot That Won the DARPA Grand Challenge. In: *Springer Tracts in Advanced Robotics - The 2005 DARPA Grand Challenge* (2005), S. 1 – 43
- [119] THRUN, S. u. a.: Stanford's Robotic Vehicle Junior: Interim Report / Stanford University. 2007. – Forschungsbericht

- [120] THRUN, S. ; BURGARD, W. ; D.FOX: *Probabilistic Robotics*. Cambridge, MA, USA : The MIT Press, 2005
- [121] TREPAGNIER, P. u. a.: KAT-5: Robust Systems for autonomous Vehicle Navigation in Challenging Unknown Terrain. In: *Springer tracts in advanced robotics - The 2005 DARAP Grand Challenge* (2007), S. 103 – 128
- [122] TRUCCO, P. ; VERRI, A.: *Introductory Techniques for 3-D Computer Vision*. Prentice Hall, 1998
- [123] URMSON, C. u. a.: A Robust Approach to High-Speed Navigation for Unrehearsed Desert Terrain. In: *Springer tracts in advanced robotics - The 2005 DARAP Grand Challenge* (2007), S. 45 – 102
- [124] URMSON, C. u. a.: Tartan Racing: A Multi-Modal Approach to the DARPA Urban Challenge. In: *Urban Challenge Semifinalists Technical Paper* (2007)
- [125] Velodyne Accoustics Inc.: *High Definition LIDAR - Velodyne's HDL 64 E*. Whitepaper. <http://www.velodyne.com/lidar>
- [126] WEINGARTEN, J.W. ; GRUENER, G. ; SIEGWART, R.: Probabilistic plane fitting in 3D and an application to robotic mapping. In: *In Proceedings of the IEEE International Conference on Robotics and Automation*, 2004, S. 927 – 932
- [127] WILLE, J.-M. ; FORM, T.: Low Level Control in a Modular System Architecture for Realizing Precise Driving Maneuvers of the Autonomous Vehicle Caroline. In: *In Proceedings of IEEE International Conference on Intelligent Transportation Systems*. Beijing, China, 2008
- [128] WILLE, J.-M. ; FORM, T.: Realizing Complex Autonomous Driving Maneuvers - The Approach Taken by Team CarOLO at the DARPA Urban Challenge. In: *In Proceedings of the IEEE International Conference on Vehicular Electronics and Safety*. Columbus, OH., USA, 2008
- [129] ZOU, Y. ; HO, Y.K. ; CHUA, C.S. ; ZHOU, X.W.: Multi-ultrasonic Sensor Fusion for Mobile robots. In: *In Proceedings of the IEEE Intelligent Vehicles Symposium 2000*, 2000, S. 387 – 391